

WALMOR CARDOSO GODOI

RECONHECIMENTO DE PADRÕES 3D EM TOMOGRAFIA INDUSTRIAL

Tese apresentada como requisito parcial à obtenção de grau de Doutor. Área de concentração: Engenharia e Ciência dos Materiais, Programa de Pós-Graduação em Engenharia e Ciência dos Materiais - PIPE. Setor de Tecnologia, Universidade Federal do Paraná.

Orientador: Prof. Dr. Vitoldo Swinka Filho

Co-orientador: Prof. Dr. Klaus de Geus

Co-orientador: Prof. Dr. Romeu Ricardo da Silva

**CURITIBA
2012**

DEDICATÓRIA

Dedico este trabalho aos meus pais, Pedro e Shirley.

AGRADECIMENTOS

Agradeço primeiramente à minha família.

Agradeço ao meu orientador Dr. Vitoldo Swinka Filho pela amizade, oportunidade, apoio, discussões e reconhecimento do meu trabalho.

Agradeço ao meu co-orientador Dr. Klaus de Geus pelas orientações, apoio, discussões sempre inovadoras e principalmente pelos *insights*.

Agradeço ao meu co-orientador Dr. Romeu Ricardo da Silva pelas orientações e parceria nos trabalhos escritos com o tema da tese.

Agradeço aos amigos Arnaldo Brasílio Filho, Edson Luis da Silva e Wilerson Sturm pelo apoio.

Agradeço aos amigos e colegas de trabalho no LACTEC, Sebastião Ribeiro Junior, Rafael Pires de Machado, Marilda Munar, Guilherme Cunha da Silva e Harlen Feijo Bório.

Agradeço às seguintes instituições que tornaram viável esta tese: ANEEL, COPEL, LACTEC, CNPq e UFPR.

Enfim, a todos que, diretamente ou indiretamente, contribuíram para a realização deste trabalho.

EPÍGRAFE

Existem 10 tipos de pessoas no mundo: as que conhecem números
binários e as que não conhecem
do twitter @piadasnerds

SUMÁRIO

LISTA DE FIGURAS	ix
LISTA DE TABELAS	xvii
LISTA DE SIGLAS	xviii
LISTA DE SÍMBOLOS	xix
RESUMO	xx
ABSTRACT	xxi
1 INTRODUÇÃO	1
1.1 ESTRUTURA DA TESE	5
2 REVISÃO DE LITERATURA	7
2.1 ENSAIOS NÃO DESTRUTIVOS	7
2.2 GERAÇÃO DE RAIOS X	8
2.2.1 ATENUAÇÃO DOS RAIOS X PELA MATÉRIA	11
2.2.2 RADIOSCOPIA INDUSTRIAL	12
2.2.1 RADIOGRAFIA DIGITAL DIRETA INDUSTRIAL	12
2.3 PROCESSAMENTO DIGITAL DE IMAGENS	13
2.3.1 IMAGEM RADIOGRÁFICA DIGITAL	14
2.3.2 PRÉ-PROCESSAMENTO DE IMAGENS DIGITAIS	14
2.3.3 SEGMENTAÇÃO DE IMAGENS DIGITAIS	15
2.4 EXTRAÇÃO DE CARACTERÍSTICAS	15
2.5 TOMOGRAFIA COMPUTADORIZADA	16
2.5.1 PROBLEMAS INVERSOS	16
2.5.3 FORMAÇÃO DO TOMOGRAMA	17

2.5.4 PROJEÇÕES DE FEIXE EM LEQUE E CONE	22
2.5.5 RECONSTRUÇÃO TOMOGRÁFICA POR RETROPROJEÇÃO SIMPLES.....	23
2.5.6 RECONSTRUÇÃO TOMOGRÁFICA POR RETROPROJEÇÃO FILTRADA.....	24
2.5.7 TOMOGRAFIA INDUSTRIAL.....	27
2.6 VISUALIZAÇÃO CIENTÍFICA E VOLUMÉTRICA.....	29
2.6.1 ALGORITMOS DE EXTRAÇÃO DE SUPERFÍCIES	31
2.6.2 ALGORITMOS DE RENDERIZAÇÃO DE VOLUMES.....	34
2.7 RECONHECIMENTO DE PADRÕES UTILIZANDO REDES NEURAS	37
2.7.1 PADRÃO DE UMA CLASSE	38
2.7.2 REDES NEURAS ARTIFICIAIS	39
2.7.3 PROCESSOS DE APRENDIZAGEM	42
2.7.4 TREINAMENTO SUPERVISIONADO	43
2.7.5 O ALGORITMO <i>BACKPROPAGATION</i>	43
2.7.6 MAPAS AUTO-ORGANIZÁVEIS DE KOHONEN	46
2.8 CONFIABILIDADE EM END	55
2.8.1 CURVAS POD (PROBABILIDADE DE DETECÇÃO)	56
2.8.2 CURVAS ROC (<i>RECEIVER OPERATING CHARACTERISTIC</i>).....	57
2.8.3 ESTIMANDO A ACURÁCIA DOS CLASSIFICADORES	58
2.9 DEFEITOS EM ISOLADORES POLIMÉRICOS.....	60
2.3 FERRAMENTAS DE DESENVOLVIMENTO COMPUTACIONAL PARA APLICAÇÕES EM TOMOGRAFIA INDUSTRIAL 3D	62
3 MATERIAIS E MÉTODOS	65
3.1 AMOSTRAS	65

3.1.1 ISOLADOR TIPO ROLDANA	65
3.1.2 ISOLADOR TIPO PINO	66
3.2 EQUIPAMENTOS UTILIZADOS.....	66
3.2.1 SISTEMA RADIOSCÓPICO	66
3.2.2 SISTEMA DIGITAL DIRETO	67
3.3 FERRAMENTAS DE DESENVOLVIMENTO E PRÁTICAS COMPUTACIONAIS UTILIZADAS	70
3.4 LEVANTAMENTO DE CARACTERÍSTICAS 3D COMO DADOS DE ENTRADA PARA RECONHECIMENTO DE PADRÕES.....	71
3.4 FLUXOGRAMA DO TRABALHO	72
4 DESENVOLVIMENTO DA MESA TOMOGRÁFICA INDUSTRIAL	74
4.1 SISTEMA MECÂNICO DA MESA TOMOGRÁFICA	74
4.2 DESENVOLVIMENTO DA INTERFACE COM O COMPUTADOR	77
4.3 MODOS DE OPERAÇÃO DO SISTEMA DE AQUISIÇÃO TOMOGRÁFICO	81
4.4 TESTES PARA RECONSTRUÇÃO DE TOMOGRAFIAS 2D	85
4.1.1 ALTERAÇÕES NO PROJETO ORIGINAL	86
5 RESULTADOS E DISCUSSÕES	90
5.1 AQUISIÇÃO DE RADIOGRAFIAS DIGITAIS.....	90
5.1.1 RADIOGRAFIAS ISOLADORES TIPO ROLDANA.....	90
5.1.2 RADIOGRAFIA ISOLADORES TIPO PINO	93
5.2 TOMOGRAFIAS 3D DE ISOLADORES.....	94
5.3 RECONHECIMENTO AUTOMÁTICO DE DEFEITOS EM TOMOGRAFIA INDUSTRIAL 3D	102
5.3.1 AGRUPAMENTO DAS CLASSES	103

5.3.2 CLASSIFICAÇÃO POR REDE NEURAL UTILIZANDO RETROPROPAGAÇÃO DE ERRO	109
6 CONCLUSÕES.....	113
7 PUBLICAÇÕES	115
8 SUGESTÕES PARA TRABALHOS FUTUROS	117
REFERÊNCIAS	118
APÊNDICE A - CÓDIGO FONTE LACVIS – <i>SOFTWARE</i> TOMOGRAFIA TRIDIMENSIONAL	130
APÊNDICE B – DADOS UTILIZADOS.....	142

LISTA DE FIGURAS

FIGURA 1 – ESQUEMA PARA FUNCIONAMENTO GERADOR DE RAIOS X. FONTE: ADAPTADO DE BUZUG [27].	9
FIGURA 2 - PROCESSO DE <i>BREMSSTRAHLUNG</i> (DESACELERAÇÃO DO ELÉTRON). FONTE: EISBERG E RESNICK [28].	10
FIGURA 3 - ESPECTRO ESQUEMÁTICO DE EMISSÃO DE RAIOS X PARA UM EQUIPAMENTO COM ALVO DE TUNGSTÊNIO. FONTE: ADAPTADO DE CORREA [29].	11
FIGURA 4 - MODELO PARA FEIXE DE RAIOS X COM SEÇÃO TRANSVERSAL A ATINGINDO UM MATERIAL DE ESPESSURA X. FONTE: GODOI, 2005 [24].	12
FIGURA 5 - RADIOGRAFIA DIGITAL DIRETA DE QUATRO ISOLADORES COM DEFEITOS EM UM DETECTOR MODELO XRD 1621 DO FABRICANTE <i>PERKIN ELMER</i> . FONTE: O AUTOR.	13
FIGURA 6 - PRINCÍPIO DA TC. DUAS PROJEÇÕES EM DOIS ÂNGULOS DISTINTOS SÃO MOSTRADAS PARA UM OBJETO COMPOSTO DE DOIS CILINDROS. FONTE: KAK E SLANEY [34].	17
FIGURA 7 - PRINCÍPIO DA TOMOGRAFIA COMPUTADORIZADA: TOMOGRAFIA POR RECONSTRUÇÃO ÓPTICA DE EDHOLM. FONTE: BUZUG [27].	19
FIGURA 8 - ATENUAÇÃO DA RADIAÇÃO EM RELAÇÃO À ESPESSURA DE UM OBJETO ANALISADO NAS EQUAÇÕES 2.7 E 2.8. FONTE: RIBEIRO-JÚNIOR [32].	20
FIGURA 9 - ATENUAÇÃO DA RADIAÇÃO EM RELAÇÃO À ESPESSURA DE UM OBJETO. FONTE: ADAPTADO DE RIBEIRO-JÚNIOR [32].	21
FIGURA 10 - PARÂMETROS PARA PROJEÇÃO DE UMA IMAGEM DE RAIOS X. FONTE: RIBEIRO-JÚNIOR [32].	21
FIGURA 11- SISTEMA DE DETECÇÃO DE FEIXE EM LEQUE DE ROTAÇÃO COM DETECTORES MÓVEIS. FONTE: RIBEIRO-JÚNIOR [32].	22
FIGURA 12 - SENOGRAMA DE UMA TOMOGRAFIA INDUSTRIAL. FONTE: ADAPTADO DE RIBEIRO-JÚNIOR [32].	24

FIGURA 13 - FLUXOGRAMA PARA SISTEMA DE DETECÇÃO EM PARALELO DE ROTAÇÃO-TRANSLAÇÃO SIMPLES. FONTE: ADAPTADO DE RIBEIRO-JÚNIOR [32]. ...	25
FIGURA 14 - CARACTERÍSTICA DO FILTRO RAM-LAK: (A) RESPOSTA NO DOMÍNIO DE FREQUÊNCIA E (B) RESPOSTA EM DOMÍNIO ESPACIAL. FONTE: ADAPTADO DE KAK E SLANEY [34].	25
FIGURA 15 - CARACTERÍSTICA DO FILTRO SHEPP-LOGAN: (A) RESPOSTA NO DOMÍNIO DE FREQUÊNCIA E (B) RESPOSTA EM DOMÍNIO ESPACIAL. FONTE: ADAPTADO DE HERMAN [36].	26
FIGURA 16 - CARACTERÍSTICA DO FILTRO HANNING: (A) RESPOSTA NO DOMÍNIO DE FREQUÊNCIA E (B) RESPOSTA EM DOMÍNIO ESPACIAL. FONTE: ADAPTADO DE HERMAN [36].	26
FIGURA 17 - CARACTERÍSTICA DO FILTRO HAMMING. FONTE: KAK E SLANEY [34]. ...	27
FIGURA 18 - ETAPAS PARA A RECONSTRUÇÃO DE UMA TOMOGRAFIA 3D: (A) PROJEÇÕES E (B) RECONSTRUÇÃO TOMOGRÁFICA 2D E 3D. FONTE: ADAPTADO DE SOUZA [55].	31
FIGURA 19 - ALGORITMO <i>CONTOUR CONNECTING</i> PARA TRÊS FATIAS TOMOGRÁFICAS. FONTE: SOUZA [55].	32
FIGURA 20 - TABELA ORIGINAL DO <i>MARCHING CUBES</i> . FONTE: LORENSEN E CLINE [53].	33
FIGURA 21 - RENDERIZAÇÃO POR: (A) <i>CONTOUR CONNECTING</i> E (B) <i>MARCHING CUBES</i> . FONTE: VTK [58].	34
FIGURA 22 - MODELOS PARA RENDERIZAÇÃO DE VOLUMES: (A) ESPAÇO DA IMAGEM (PROCESSA VÁRIOS <i>VOXELS</i> PARA DEFINIR UM <i>PIXEL</i> NA TELA) E (B) ESPAÇO DO OBJETO (PROCESSA UM <i>VOXEL</i> PARA COMPUTAR ALGUNS <i>PIXELS</i> NA TELA). FONTE: ADAPTADO DE PAIVA <i>ET AL.</i> [52].	35
FIGURA 23 - COMPARAÇÃO ENTRE DOIS ALGORITMOS PARA RECONSTRUÇÃO DE VOLUME. À ESQUERDA VOLUME RECONSTRUÍDO PELO ALGORITMO DE	

<i>BRESENHAM</i> E À DIREITA PELO ALGORITMO DE <i>TRIPOD</i> . FONTE: PAIVA ET AL. [52].	
.....	36
FIGURA 24 - MODELOS PARA RENDERIZAÇÃO DE VOLUMES POR <i>RAY CASTING</i> . FONTE: PAIVA [52].	36
FIGURA 25 - EXEMPLO DE DISTRIBUIÇÃO DE CLASSES PARA DADOS “IRIS” DE FISHER [64]. O GRÁFICO ILUSTRA TRÊS TIPOS DE CLASSES (OU SEJA, TRÊS TIPOS DE FLORES) QUE PODERIAM SER SEPARADAS POR UM CLASSIFICADOR APENAS COM O LEVANTAMENTO DE DUAS CARACTERÍSTICAS: COMPRIMENTO E LARGURA DE PÉTALAS. FONTE: ADAPTADO DE FISHER [64].	39
FIGURA 26 - FASE DE PROPAGAÇÃO. FONTE: LNCC [71].	44
FIGURA 27 - FASE DE RETROPROPAGAÇÃO. FONTE: LNCC [71].	44
FIGURA 28 - ARQUITETURA REDE SOM. FONTE: FAUSETT [74].	48
FIGURA 29 - MODELO PARA UM VETOR LINEAR DE UNIDADES DE CLUSTERS E SUA RELAÇÃO COM O RAIO R: PARA { }, R=2, (), R=1 E [], R=0. FONTE: FAUSETT [74].	48
FIGURA 30 - REPRESENTAÇÃO VIZINHOS “*” A UMA UNIDADE CLUSTER “#” REDE SOM PARA MAPA RETANGULAR. FONTE: FAUSETT [74].	48
FIGURA 31 - REPRESENTAÇÃO VIZINHOS “*” A UMA UNIDADE CLUSTER “#” REDE SOM PARA MAPA HEXAGONAL. FONTE: FAUSETT [74].	49
FIGURA 32 - MODELO REDE SOM: ENTRADA, CAMADA (<i>W</i> É O FATOR DE PESO DA REDE) E SAÍDA. FONTE: MANUAL MATLAB [75].	52
FIGURA 33 - TOPOLOGIA REDE SOM COM 64 NODOS. FONTE: MANUAL MATLAB [75].	53
FIGURA 34 - PESOS OBTIDOS DA REDE SOM PARA OS DADOS DA TABELA 1. FONTE: O AUTOR.	54
FIGURA 35 - PESOS DOS NEURÔNIOS PARA A REDE SOM DOS DADOS DE FISHER [64]. PLANO DE PESOS PARA CADA UMA DAS QUATRO CARACTERÍSTICAS DAS flores (F1 ATÉ F4). CORES ESCURAS REPRESENTAM TODOS PESOS ALTOS PARA	

OS DADOS DE ENTRADA. F3 E F4 MOSTRAM MELHOR A SEPARAÇÃO DAS TRÊS CLASSES. FONTE: MANUAL MATLAB [75].	55
FIGURA 36 - MODELO DE CURVAS POD REAL E IDEAL. FONTE: CARVALHO [76].	56
FIGURA 37 - MODELO DE CURVA ROC. FONTE: SILVA [78].	57
FIGURA 38 - RADIOGRAFIA DIGITAL DE UM ISOLADOR TIPO ROLDANA, ONDE OS FALSOS-POSITIVOS, NESTE CASO, <i>PIXELS</i> DEFEITUOSOS DO DETECTOR DIGITAL (ARTEFATO TIPO ESTRELAS INDICADO PELOS CÍRCULOS) E UMA BOLHA REAL (VERDADEIRO-POSITIVO, DENTRO DO QUADRADO PRETO) PODEM SER VISTOS. FONTE: O AUTOR.	58
FIGURA 39 - MODELO PARA GRADIENTE DE TEMPERATURA EM UM ISOLADOR TIPO PINO EM PROCESSO DE RESFRIAMENTO E O SURGIMENTO DE UMA BOLHA DE AR. AS REGIÕES INTERNAS T2 RESFRIAM MAIS LENTAMENTE QUE AS REGIÕES PRÓXIMAS À SUPERFÍCIE T1. FONTE: O AUTOR.	61
FIGURA 40 - DESENHO ESQUEMÁTICO DO ISOLADOR POLIMÉRICO TIPO ROLDANA. MEDIDAS EM MILÍMETROS. F É A DIREÇÃO DA FORÇA APLICADA PELO CABO. FONTE: VICENTINOS DO BRASIL [87].	65
FIGURA 41 - DIAGRAMA ISOLADOR POLIMÉRICO TIPO PINO. AS DIMENSÕES PARA A VARIAM DE 130 MM A 180 MM, PARA B DE 140 MM A 190 MM, C DE 89 MM A 95 MM E D=45 MM. FONTE: VICENTINOS DO BRASIL [87].	66
FIGURA 42 - SISTEMA DE RADIOSCOPIA. FONTE: O AUTOR.	67
FIGURA 43 - DETALHE DO INTENSIFICADOR DE IMAGENS DO SISTEMA DE RADIOSCOPIA MOSTRADO NA FIGURA 42. FONTE: O AUTOR.	67
FIGURA 44 - SISTEMA DIGITAL DIRETO COM DETECTOR A-SI (<i>FLAT PANEL</i>). PARA FUNCIONAMENTO, A FONTE DE RAIOS X MICROFOCO FUNCIONA COM 12 VDC NA ENTRADA. O DETECTOR DIGITAL DIRETO POSSUI ÁREA ATIVA DE 12 CM X 11 CM E ESTÁ LIGADO AO COMPUTADOR POR UMA PLACA PCI. FONTE: O AUTOR.	68

FIGURA 45 – DETALHE DE DETECTOR DIGITAL DE RAIOS X (<i>FLAT PANEL</i>). FONTE: O AUTOR.....	68
FIGURA 46 - ARRANJO EXPERIMENTAL UTILIZADO NA AQUISIÇÃO DAS TOMOGRAFIAS NO SISTEMA DIGITAL DIRETO. FONTE: O AUTOR.....	69
FIGURA 47 - GERADOR DE RAIOS X MICROFOCO UTILIZADO NO SISTEMA DIGITAL DIRETO. FONTE: O AUTOR.	69
FIGURA 48 - INTERFACE COM O USUÁRIO DA FERRAMENTA COMPUTACIONAL DE RECONSTRUÇÕES DE TOMOGRAFIAS 2D. A IMAGEM MOSTRA A RADIOGRAFIA DE UM ISOLADOR TIPO PINO COM BOLHA INTERNA (SETA). FONTE: PIEKARZ [31].	71
FIGURA 49 - FLUXOGRAMA DO TRABALHO DESENVOLVIDO. FONTE: O AUTOR.	73
FIGURA 50 - PROJETO CAD DA MESA TOMOGRÁFICA: COMPONENTE RESPONSÁVEL PELOS DESLOCAMENTOS VERTICAL, HORIZONTAL E DE ROTAÇÃO DA AMOSTRA. FONTE: O AUTOR.....	74
FIGURA 51 - POLIAS DE SINCRONIZAÇÃO DOS FUSOS DE ELEVAÇÃO DA MESA TOMOGRÁFICA. FONTE: O AUTOR.....	75
FIGURA 52 - PROJETO CAD DA MESA TOMOGRÁFICA EM SUA COMPOSIÇÃO TOTAL. FONTE: O AUTOR.....	76
FIGURA 53 - PROTÓTIPO COM A FONTE DE RAIOS X (LADO DIREITO) E DETECTOR DIGITAL PLANO DE RAIOS X (LADO ESQUERDO). FONTE: O AUTOR.....	76
FIGURA 54 - PAINEL DE COMANDO DA MESA TOMOGRÁFICA. FONTE: O AUTOR.....	77
FIGURA 55 - PLACA COM OS CIRCUITOS OPTOACOPLORES. FONTE: O AUTOR..	78
FIGURA 56 - DIAGRAMA ELETRÔNICO DO DISPOSITIVO OPTOACOPLADOR PARA ACIONAMENTO DE RELÉ 24V. FONTE: O AUTOR.	79
FIGURA 57 - DIAGRAMA ELETRÔNICO DO DISPOSITIVO OPTOACOPLADOR PARA ACIONAMENTO DO DRIVE DO MOTOR DE PASSO. FONTE: O AUTOR.....	80
FIGURA 58 - DIAGRAMA ELETRÔNICO DO DISPOSITIVO OPTOACOPLADOR PARA LEITURA DOS SINAIS DOS SENSORES FIM DE CURSO. FONTE: O AUTOR.....	80

FIGURA 59 - VISTA LATERAL DO PAINEL DE COMANDO. FONTE: O AUTOR.....	82
FIGURA 60 - VISTA DO PAINEL DE COMANDO COM CHAVE SELETORA PARA MANUAL OU AUTOMÁTICO. FONTE: O AUTOR.....	82
FIGURA 61 - <i>JOYSTICK</i> PARA MOVIMENTAÇÃO MANUAL DA MESA. FONTE: O AUTOR.	83
FIGURA 62 - DIAGRAMA ELÉTRICO DO INTERTRAVAMENTO DA CHAVE SELETORA. FONTE: O AUTOR.....	84
FIGURA 63 - COMPONENTES DO PAINEL DE COMANDO. FONTE: O AUTOR.	84
FIGURA 64: FOTO PHANTOM DE ACRÍLICO COM FUROS DE 1 MM A 6 MM. FONTE: O AUTOR.....	86
FIGURA 65 - TOMOGRAFIA DE UM <i>PHANTOM</i> DE ACRÍLICO. (A) UTILIZANDO 8 PULSOS NO MOTOR DE PASSO PARA ROTACIONAR A MESA E (B) UTILIZANDO 9 PULSOS (OU PASSO DE 0,9 GRAUS). FONTE: O AUTOR.	86
FIGURA 66 - RADIOGRAFIA DE ISOLADOR ROLDANA COM IMPUREZAS NO MATERIAL E ARTEFATO TIPO “ESTRELA”. PARÂMETROS DE AQUISIÇÃO: 70KV, 0,01 MA, 5 S. FONTE: O AUTOR.....	91
FIGURA 67 – RADIOGRAFIA DE ISOLADOR ROLDANA COM DEFEITO (BOLHA). PARÂMETROS DE AQUISIÇÃO: 70KV, 0,01 MA, 5 S. FONTE: O AUTOR.	91
FIGURA 68 - RADIOGRFIA DE ISOLADOR ROLDANA COM DEFEITO (IMPUREZAS NO MATERIAL). PARÂMETROS DE AQUISIÇÃO: 70KV, 0,01 MA, 5 S. FONTE: O AUTOR....	92
FIGURA 69 - RADIOGRAFIA DE ISOLADOR ROLDANA COM DEFEITO (IMPUREZAS NO MATERIAL). PARÂMETROS DE AQUISIÇÃO: 70KV, 0,01 MA, 5 S. FONTE: O AUTOR....	92
FIGURA 70 - RADIOGRAFIA DE ISOLADOR ROLDANA COM DEFEITO (IMPUREZAS NO MATERIAL). PARÂMETROS DE AQUISIÇÃO: 70KV, 0,01 MA, 5 S. FONTE: O AUTOR....	93
FIGURA 71 - (A) RADIOGRAFIA DE ISOLADOR TIPO ROLDANA. PARÂMETROS DE AQUISIÇÃO: 70KV, 0,01 MA, 5 S . (B) FATIA TOMOGRÁFICA APRESENTANDO BOLHAS. NA IMAGEM PODE-SE VER 5 BOLHAS INDICADAS PELAS SETAS. FONTE: O AUTOR.	93

FIGURA 72 - RADIOGRAFIA DE ISOLADOR TIPO PINO OBTIDA EM SISTEMA COM INTENSIFICADOR DE IMAGENS DA FIGURA 42. AS SETAS INDICAM DUAS BOLHAS. FONTE: O AUTOR.....	94
FIGURA 73 - INTERFACE <i>SOFTWARE</i> LACVIS: INTERFACE COM O USUÁRIO DA FERRAMENTA COMPUTACIONAL DE RECONSTRUÇÃO DE TOMOGRAFIAS 3D NO SISTEMA OPERACIONAL LINUX 64 BITS. A IMAGEM PRESENTE É A DA TOMOGRAFIA 3D DE UM ISOLADOR POLIMÉRICO TIPO ROLDANA. FONTE: O AUTOR.....	95
FIGURA 74 - RENDERIZAÇÃO SUPERFÍCIE DO ISOLADOR TIPO PINO E CARACTERÍSTICAS CALCULADAS PELO LACVIS DE F1 ATÉ F9. FONTE: O AUTOR. ...	97
FIGURA 75 - RENDERIZAÇÃO DE BOLHA INTERNA DO ISOLADOR MOSTRADO NA FIGURA 74 E AS CARACTERÍSTICAS CALCULADAS PELO LACVIS DE F1 ATÉ F9. FONTE: O AUTOR.....	97
FIGURA 76 - RECONSTRUÇÃO TRIDIMENSIONAL DE UM ISOLADOR TIPO PINO POR <i>MARCHING CUBES</i> E LISTAGEM DE CARACTERÍSTICAS MEDIDAS QUE APARECEM NA TELA, JUNTAMENTE COM O NÚMERO DO OBJETO RECONSTRUÍDO. FONTE: O AUTOR.....	98
FIGURA 77 - VISUALIZAÇÃO SUPERFÍCIE TOMOGRAFIA 3D DO ISOLADOR TIPO ROLDANA A PARTIR DAS TOMOGRAFIAS OBTIDAS, UTILIZANDO O ALGORITMO DE <i>MARCHING CUBES</i> . FONTE: O AUTOR.....	99
FIGURA 78 - TOMOGRAFIA TRIDIMENSIONAL DO VOLUME RECONSTRUÍDO POR <i>RAY CASTING</i> DE ISOLADOR TIPO PINO. FONTE: O AUTOR.	100
FIGURA 79 - DETALHE DA MALHA POLIGONAL RECONSTRUÍDA POR <i>MARCHING CUBES</i> DE ISOLADOR TIPO PINO. PODE-SE VER UMA BOLHA INTERNA NA PARTE SUPERIOR DO ISOLADOR. FONTE: O AUTOR.....	100
FIGURA 80 - MALHA POLIGONAL RECONSTRUÍDA POR <i>MARCHING CUBES</i> DE ISOLADOR TIPO PINO. PODE-SE VER UMA BOLHA INTERNA NA PARTE SUPERIOR DO ISOLADOR. FONTE: O AUTOR.....	101

FIGURA 81 - (A) RADIOGRAFIA DIGITAL COM UTILIZAÇÃO DE DETECTOR DIGITAL PLANO DE RAIOS X DA AMOSTRA DA FIGURA 80 ONDE FOI ADQUIRIDA APENAS PARTE SUPERIOR DO ISOLADOR TIPO PINO. HÁ PRESENÇA DE UMA BOLHA E CAMINHO DE DESCARGA ELÉTRICA (INDICADA PELA SETA PRETA). (B) RECONSTRUÇÃO TRIDIMENSIONAL DA REGIÃO DA BOLHA MOSTRADA NA TOMOGRAFIA 3D DA FIGURA 80 E NA RADIOGRAFIA DE (A) EM DETALHE. A IMAGEM PERMITE VER O CAMINHO DE RUPTURA DIELÉTRICA ATRAVESSANDO O VAZIO (SETA BRANCA). FONTE: O AUTOR.....	102
FIGURA 82 - SEPARAÇÃO DOS PADRÕES EM DUAS DIMENSÕES CONSIDERANDO AS CARACTERÍSTICAS F7 X F9. FONTE: O AUTOR.....	104
FIGURA 83 - MAPA DISTÂNCIA VIZINHOS SOM 10 X 10 NODOS. AGRUPAMENTO PARA SEPARAÇÃO DAS CLASSES DEFEITO (D) OU ESTRUTURA REGULAR (ER). FONTE: O AUTOR.....	105
FIGURA 84 - MAPA DE AGRUPAMENTO PARA CADA CARACTERÍSTICA COM 100 NEURÔNIOS. AO TODO SÃO NOVE CARACTERÍSTICAS (NO MAPA, CARACTERÍSTICAS DE F1 ATÉ F9). FONTE: O AUTOR.....	106
FIGURA 85 - CURVA DE DESEMPENHO DA REDE NEURAL COM 20 NEURÔNIOS NA SUBCAMADA. FONTE: O AUTOR.	108
FIGURA 86 - CURVA ROC RESULTANTE DOS GRUPOS SELECIONADOS ALEATORIAMENTE SEM REPOSIÇÃO DE DADOS (TABELA 11). FONTE: O AUTOR...	111

LISTA DE TABELAS

TABELA 1 - DADOS HIPOTÉTICOS QUE COMPÕE O VETOR DE ENTRADA DO EXEMPLO APRESENTADO EM 1990 POR KOHONEN [73].	53
TABELA 2 - CARACTERÍSTICAS DOS SISTEMAS DE RADIOGRAFIA INDUSTRIAL UTILIZADOS. FONTE: O AUTOR.....	70
TABELA 3 - CARACTERÍSTICAS (F1 ATÉ F9) CALCULADAS DOS OBJETOS 3D TOMOGRÁFICOS RECONSTRUÍDOS. TODAS SÃO CARACTERÍSTICAS DE NATUREZA GEOMÉTRICA. FONTE: O AUTOR.....	72
TABELA 4 - DESCRIÇÃO SINAIS DOS OPTOACOPLOADORES. FONTE: O AUTOR.....	79
TABELA 5 - DESCRIÇÃO DOS COMPONENTES INTERNOS DO PAINEL DE COMANDO DA FIGURA 61. FONTE: O AUTOR.	85
TABELA 6 - RESULTADOS DAS MEDIDAS OBTIDAS PARA TESTES DE ROTAÇÃO DA MESA UTILIZANDO O MOTOR DE PASSO. FONTE: O AUTOR.....	88
TABELA 7 - COFICIENTES DE CORRELAÇÃO LINEAR ENTRE AS CARACTERÍSTICAS E CLASSES DE PADRÕES. FONTE: O AUTOR.....	103
TABELA 8 - CORRELAÇÃO SIGNIFICATIVA ENTRE AS CARACTERÍSTICAS POR CÁLCULO DE P-VALOR ($P < 0,05$). FONTE: O AUTOR.....	107
TABELA 9 - ERRO MÉDIO QUADRÁTICO DA REDE NEURAL SOM. FONTE: O AUTOR.	108
TABELA 10 - VARIAÇÃO DO NÚMERO DE NEURÔNIOS NA CAMADA INTERMEDIÁRIA. FONTE: O AUTOR.....	109
TABELA 11 - ACURÁCIA ESTIMADA PARA CLASSIFICADOR NÃO LINEAR POR SELEÇÃO ALEATÓRIA SEM REPOSIÇÃO (NÚMERO DE VERDADEIROS POSITIVOS EM %). FONTE: O AUTOR.....	110
TABELA 12 - ACURÁCIA ESTIMADA DO CLASSIFICADOR NÃO LINEAR POR TÉCNICA DE <i>BOOTSTRAP</i> (NÚMERO DE VERDADEIROS POSITIVO). FONTE: O AUTOR.	112

LISTA DE SIGLAS

ABENDI	Associação Brasileira de Ensaios Não Destrutivos e Inspeção
CELG	Companhia Energética de Goiás
DAC	Diagnóstico Auxiliado por Computador
DTA	<i>Divergence Theorem Algorithm</i>
END	Ensaios Não Destrutivos
EPDM	Etileno Propileno Dieno Monômero
EPR	Etileno PPropileno
GE	<i>General Electric</i>
IAC	Inspeção Auxiliada por Computador
IDE	<i>Integrated Development Environment</i>
ITK	<i>Insight Toolkit</i>
LACTEC	Instituto de Tecnologia para Desenvolvimento
MATLAB	<i>MATrix LABoratory</i>
MRI	<i>Magnetic Resonance Imaging</i>
MUNC	<i>Maximum Unit Normal Component</i>
NSI	<i>Normalized Shape Index</i>
OCR	<i>Optical Character Recognition</i>
PCL	Policaprolactona
PDI	Processamento Digital de Imagens
PET	<i>Positron Emission Tomography</i>
Pixel	<i>Picture Element</i>
PoD	<i>Probability of Detection</i>
ROC	<i>Receiver Operating Characteristic</i>
SOM	<i>Self Organizing Map</i>
SPECT	<i>Single Photon Emission Computed Tomography</i>
STL	Stereolitografia
TC	Tomografia Computadorizada
UV	Ultravioleta
ViSC	<i>Visualization in Scientific Computing</i>
Voxel	<i>Volume element</i>
VTK	<i>Visualization Toolkit</i>

LISTA DE SÍMBOLOS

c	Velocidade da luz = $3,00 \times 10^8$ m/s
e	Carga do elétron = $-1,60 \times 10^{-19}$ C
eV	elétron-volt
h	Constante de Planck = $6,63 \times 10^{-34}$ m ² kg/s
kV	quilovolts
keV	quilo-elétron-volt
mA	mili-Ampère
v	Velocidade
\AA	Ångstrom = 10^{-10} m

RESUMO

Esta tese apresenta nova proposta metodológica para reconhecimento de padrões 3D em tomografias industriais. Para testes e validação da metodologia desenvolvida foi abordado o estudo de caso de defeitos em isoladores poliméricos utilizados em redes de distribuição de energia elétrica. A metodologia proposta inicia-se com a reconstrução de fatias tomográficas, obtidas utilizando-se projeções em dois sistemas de aquisição de radiografias industriais. As fatias tomográficas reconstruídas a partir das aquisições nos dois sistemas foram compostas por 8 bits de resolução em profundidade (256 tons de cinza). A segmentação e renderização 3D dos objetos nas tomografias foram realizadas mediante o uso do algoritmo *Marching Cubes*, implementado na biblioteca *open-source Visualization Toolkit* (VTK) em linguagem de programação Java. A nova metodologia proposta aqui obtém características tridimensionais das estruturas regulares (ER) e de defeitos (D) nas tomografias industriais dos componentes ensaiados. Assim, utilizaram-se nove características tridimensionais calculadas diretamente dos objetos reconstruídos nas tomografias 3D dos componentes, a partir das imagens 3D das superfícies geradas pelo método *Marching Cubes*. Na sequência, utilizaram-se treinamentos e testes em Rede Neural SOM e rede supervisionada Feedforward Backpropagation, com o objetivo de realizar a separação das duas classes que devem ser detectadas, a saber, estrutura regular (ER) e defeito (D). Para o número de amostras utilizadas, os resultados obtidos foram promissores. A inovação deste trabalho está na metodologia proposta, dado que a literatura científica não relata trabalhos para reconhecimento de padrões 3D em tomografia industrial.

Palavras-chaves: Reconhecimento de padrões 3D; tomografia computadorizada industrial; redes neurais; visualização científica; isoladores poliméricos.

ABSTRACT

This thesis presents a new methodology for 3D pattern recognition in industrial tomography. A case study of defects in polymeric insulators used in power distribution networks was discussed in order to test and validate the methodology. The proposed methodology begins with the reconstruction of tomographic slices obtained using projections in two industrial radiography acquisition systems. The tomographic slices reconstructed from the acquisitions in the two systems had 8 bits of resolution (256 shades of grey). The 3D segmentation and rendering of objects in the scans were performed by means of the Marching Cubes algorithm, implemented in the open-source Visualization Toolkit (VTK), using the Java programming language. The proposed innovation lies in obtaining three-dimensional characteristics of regular structures (ER) and defects (D) in scans of industrial components, which are need for the classification process. Thus, nine three-dimensional characteristics directly calculated from the objects reconstructed from 3D CT scans of components were used, based on the 3D images of surfaces generated by the Marching Cubes algorithm. Then training and testing were performed on a SOM Neural Network and on a supervised Feedforward Backpropagation network, in order to achieve the separation of the two classes that should be detected, namely, regular structures (ER) and defects (D). Considering the number of samples used, the results were promising. The innovation of this work lies in the proposed methodology, since the scientific literature does not report works addressing 3D pattern recognition in industrial tomography.

Keywords: 3D pattern recognition; industrial CT; neural networks, scientific visualization; insulators.

1 INTRODUÇÃO

A Associação Brasileira de Ensaios Não Destrutivos e Inspeção (ABENDI) afirma que o Ensaio Não Destrutivo (END) consiste de um conjunto de técnicas utilizadas na inspeção de materiais e equipamentos, sendo executadas nas etapas de fabricação, construção, montagem, manutenção e operação. Ainda, de acordo com a ABENDI, os métodos mais usuais de END são ensaio visual, líquido penetrante, partículas magnéticas, ultrassom, radiografias e tomografias industriais, gamagrafia, correntes parasitas, análise de vibrações, termografia, emissão acústica e análise de deformações. A importância do END está na possibilidade de avaliar, tanto no local de instalação quanto em laboratório, um componente, sem modificar suas características físicas, mecânicas e dimensionais e sem comprometer o seu uso no futuro [1].

No diagnóstico médico, existe a preocupação em se reconhecer automaticamente estruturas patológicas. Exemplos de estudos com esse objetivo utilizam técnicas para reconhecimento de padrões em imagens bidimensionais por mamografia [2], tomografia por raios X para detecção de nódulos no pulmão [3,4,5] ou calcificações na aorta [6], ressonância magnética [7], em medicina nuclear [8], etc. Esse tipo de aplicação envolve uma área da medicina denominada Diagnóstico Auxiliado por Computador (DAC) [9].

Em END, também existem demandas para aplicações que envolvam reconhecimento automático de defeitos. Sabe-se que as metodologias médicas possuem especificidades associadas à detecção de estruturas anatômicas humanas, mas os trabalhos que mostram aplicações envolvendo DAC podem servir de inspiração para o desenvolvimento de aplicações em reconhecimento de padrões em técnicas de END que envolvam imagens, como, por exemplo, em radiografias e tomografias industriais. O sucesso de empreitadas nesse sentido pode definir um novo termo, que será denominado aqui de Inspeção Auxiliada por Computador (IAC), dado que em END não se utiliza o termo diagnóstico. Nesse sentido, reconhecer automaticamente objetos em imagens tomográficas industriais tridimensionais pode servir como uma poderosa ferramenta, possibilitando a inspeção de diversos componentes, prever acidentes, localizar e quantificar defeitos, auxiliar no desenvolvimento de novos produtos, etc.

A grande valia dos métodos automáticos de inspeção em END é se obter 100% de confiabilidade, haja visto que os métodos manuais dependem de vários fatores subjetivos. Por exemplo, PÁDUA *et al.* [10] e MERY [11] mostraram aplicações para inspeção automática de defeitos em detecção de discontinuidades em radiografia de soldas. CARRASCO e MERY [12] mostraram as aplicações de inspeção automática em rodas de alumínio.

Os trabalhos anteriores baseiam-se em dados com levantamento de informações bidimensionais. Algumas abordagens em reconhecimento tridimensional podem ser citadas. Por exemplo, reconhecimento de padrões 3D facial para aplicações no setor de segurança [13,14,15]. CHEN e BHANU [16] utilizaram descritores locais de superfície para o reconhecimento de padrões 3D de objetos com formas variadas. HAM e PARK [17] utilizaram modelos de Markov e redes neurais para reconhecer objetos tridimensionais, tais como: esferas, cilindros e paralelepípedos, calculando características tridimensionais dos objetos, tais como área superficial e momento 3D (vetores normais à superfície de um objeto tridimensional).

Citam-se na sequência alguns exemplos de aplicações do reconhecimento de padrões 3D em tomografias médicas e algumas aplicações de reconhecimento 3D em engenharia. As aplicações envolvendo reconhecimento de padrões 3D em medicina, em sua maioria, recorrem a elementos bidimensionais das projeções ou fatias tomográficas. As aplicações em engenharia recorrem a características geométricas 2D dos modelos ou dados tridimensionais obtidos por sistemas de digitalização.

KITA *et al.* [18] mostraram um sistema para detecção 3D de lesões em mamografias. O sistema desenvolvido estima a posição das lesões no espaço tridimensional a partir de duas imagens bidimensionais da mama (duas mamografias, em duas vistas diferentes). Os resultados obtidos pelos autores são promissores para aplicações clínicas em localização automática de tumores em mamografia estereoscópica e em ressonância magnética tridimensional.

STALL *et al.* [19] desenvolveram um sistema para segmentação automática e identificação dos ossos do abdômen numa imagem tridimensional de Tomografia Computadorizada (TC). Eles ressaltam cinco estágios para o sucesso dessa

abordagem: (1) detecção das estruturas relevantes na imagem, (2) construção das primitivas da imagem, (3) classificação das primitivas, (4) “clusterização” e reconhecimento de primitivas classificadas e (5) segmentação total baseada nos grupos de imagem criados.

DI BONA *et al.* [20] fizeram uma abordagem para a classificação da massa cerebral em tomografias obtidas por TC e MRI. Essa abordagem teve como objetivo detectar patologias que estão relacionadas com a estrutura anatômica ou regiões ativadas do cérebro.

HAM e PARK [21], em seu trabalho, utilizaram redes neurais juntamente com modelos de Markov para o reconhecimento dos objetos 3D. As características para o treinamento da rede neural de HAM e PARK foram baseadas em características bidimensionais como o tipo de superfície, o momento, a área, etc.

SON e KIM [22] propuseram uma aplicação de reconhecimento automático 3D para estruturas de construções, utilizando dados providos por sistemas de visão 3D para monitoramento de progresso de construções.

GOLOSIO *et al* [23] propuseram uma abordagem morfológica para a extração de volumes em regiões de interesse de características não *conhecidas a priori*. Esse pode ser o caso dos tecidos cancerosos diagnosticados em tomografia médica ou defeitos encontrados em tomografia industrial. O volume de interesse é definido por meio de seleção semi-automática de um pequeno grupo de bordas de contorno em diferentes planos. Tais contornos são, então, conectados por meio de técnicas de *morphing* para interpolar as superfícies cortadas.

Podem-se dividir as aplicações em tomografia médica ou industrial, objetivando reconhecimento de padrões 2D e 3D, resumidamente, como descrito a seguir, sendo o terceiro item o utilizado neste trabalho para imagens tomográficas 3D industriais:

1. reconhecimento de padrões em domínio 2D apenas (fatias ou projeções radiográficas). Muitas aplicações médicas e algumas aplicações em radiografia industrial.
2. reconhecimento de padrões 3D a partir do domínio 2D. Muitas aplicações médicas seguem esse paradigma. Utilizada, também, em aplicações de

engenharia e reconhecimento facial e algumas aplicações em tomografia industrial.

3. reconhecimento de padrões, diretamente, a partir do domínio espacial 3D. Algumas aplicações propostas na área médica, porém nenhuma em tomografia industrial.

A necessidade de inspetores treinados para atuação em radiografia industrial, a quantificação e a diversidade de tipos de falhas que um componente pode possuir é a demanda por ferramentas que possam auxiliar no laudo técnico. Podem ser justificativas para o desenvolvimento desta tese, um exemplo a ser considerado, como o estudo de caso, é o de componentes elétricos, isoladores de pino e roldana classe 15 kV. Esses componentes, geralmente feitos de polietileno de alta densidade, podem apresentar defeitos, tais como bolhas e trincas, devido ao processo de fabricação ou mesmo devido ao seu uso na rede elétrica [24]. Devido as características do tipo de defeito que ocorre nesses componentes, tais como as bolhas, uma ferramenta de inspeção que possa identificar e quantificar as propriedades do defeito, em escala tridimensional, deve aumentar o controle de qualidade desses componentes ou mesmo auxiliar no desenvolvimento de projetos de novos isoladores. Estes sempre estão sujeitos a problemas de descargas elétricas e ruptura mecânica (quando instalados), que causam prejuízos à concessionária de energia quando falham.

Foi realizada uma exaustiva busca por sistemas comerciais para a realização das tomografias industriais dedicadas à inspeção de componentes elétricos. Não existem sistemas dedicados à detecção automática de defeitos em tomografias 3D industriais. No que concerne ao reconhecimento automático de padrões em tomografia industrial 3D, ou seja, reconhecimento de objetos no espaço 3D, não existem metodologias ou produtos disponíveis. Apenas algumas aplicações em medicina foram relatadas, conforme citado, as quais envolveram o reconhecimento de estruturas bidimensionais em imagens bi ou tridimensionais, sempre a partir de estruturas bidimensionais em imagens tomográficas, ou seja, esses estudos foram baseados em fatias (imagens 2D).

Tendo em vista as justificativas apresentadas para reconhecimento de padrões 3D em tomografia industrial é necessário desenvolver metodologia para

realizar reconhecimento de padrões tridimensionais em imagens tomográficas industriais.

Para isso objetivou-se realizar nesta tese os seguintes passos: (i) desenvolvimento de instrumentação para a construção de um protótipo de tomógrafo industrial, (ii) desenvolvimento de metodologia baseada em reconhecimento de padrões tridimensionais, utilizando técnicas de redes neurais e ViSC, a partir de imagens de tomografia computadorizada industrial 3D, (iii) desenvolvimento de ferramenta computacional para reconstrução de tomografias 3D, (iv) definição e levantamento de características espaciais a partir de tomografias 3D, (v) utilizar, como estudo de caso e para realização de testes, o sistema desenvolvido na detecção automática de defeitos a partir das tomografias 3D de componentes utilizados no setor de distribuição de energia elétrica (isoladores poliméricos tipo pino e roldana) e (vi) validar estatisticamente os resultados encontrados para o estudo de caso citado em (v).

1.1 ESTRUTURA DA TESE

Esta tese está organizada conforme segue.

No Capítulo 2 está apresentada uma breve revisão dos seguintes tópicos: geração de raios X, tomografia computadorizada (o problema inverso, reconstrução tomográfica e as aplicações da tomografia industrial), algoritmos de renderização de superfícies, algoritmos de “renderização” de volumes e reconhecimento de padrões, citando as aplicações em tomografia médica e engenharia.

No Capítulo 3, está descrita a metodologia experimental utilizada, descrevendo as amostras utilizadas, os equipamentos, a instrumentação desenvolvida para a construção da mesa tomográfica industrial e a ferramenta computacional desenvolvida para visualização e detecção automática de defeitos.

No Capítulo 4, está apresentada a instrumentação para o desenvolvimento da mesa tomográfica.

No Capítulo 5 estão apresentados os resultados das aquisições radiográficas e reconstrução de imagens 3D a partir da ferramenta computacional desenvolvida e os resultados de treinamento, teste e validação das redes neurais artificiais para a detecção automática de defeitos utilizando nove características

tridimensionais extraídas das imagens renderizadas por *Marching Cubes* dos isoladores.

No Capítulo 6, estão apresentadas as conclusões do trabalho.

No Capítulo 7 apresentam-se a relação das publicações realizadas em revistas e congressos internacionais.

No Capítulo 8 apresentam-se as sugestões para trabalhos futuros.

No Apêndice A está apresentado o código fonte da ferramenta computacional desenvolvida, denominada LACVIS. O código está comentado e resumido e foi escrito em linguagem de programação Java.

No Apêndice B apresentam-se os dados das nove características tridimensionais calculadas e utilizadas no desenvolvimento dos experimentos desta tese.

2 REVISÃO DE LITERATURA

Neste capítulo, estão apresentados os conceitos utilizados no desenvolvimento desta tese. Inicialmente, é apresentada uma breve introdução sobre o conceito de END e a tomografia industrial. Alguns conceitos relacionados a este trabalho como a produção de raios X, formação e processamento digital de imagens radiográficas também estão mostrados. Além disso, apresentam-se a reconstrução de imagens tomográficas 2D, sendo referenciadas algumas aplicações da tomografia na indústria. Os algoritmos para renderização de superfícies e volumes utilizados em tomografia tridimensional estão apresentados na sequência. Ao final, fez-se uma abordagem da estrutura de funcionamento das redes neurais.

2.1 ENSAIOS NÃO DESTRUTIVOS

A literatura relata que o primeiro teste não destrutivo da história pode ter sido a experiência de Arquimedes (287 a.C. à 212 a.C.) na investigação das proporções de ouro e prata na coroa do rei Hierão II (306 a.C. - 215 a.C.) de Siracusa. Ele deveria descobrir as razões percentuais de ouro e prata na coroa sem danificá-la (meramente, a aplicação do princípio que rege o fenômeno do empuxo). Diversas aplicações e novas tecnologias de inspeção foram surgindo com o tempo. Entre os anos 1930 e 1940, a importância dos END foi devidamente reconhecida. Desde então, suas aplicações, juntamente com o maior entendimento do comportamento e dos modos de falha dos materiais, foram essenciais para a produção de equipamentos confiabilidade em funcionamento [1].

No contexto das ciências e engenharia, a TC é uma técnica de END que visa a obter imagens tridimensionais de objetos sólidos [25]. Desde sua criação na década de 70, surgiram várias técnicas que competem ou aliam-se à TC por raios X, tais como a Imagem por Ressonância Magnética (MRI - *Magnetic Resonance Imaging*), na medicina nuclear em Tomografia por Emissão de Pósitrons (PET - *Positron Emission Tomography*), na Tomografia por Emissão Fóton Único (SPECT - *Single Photon Emission Computed Tomography*), Tomografia com Feixe de Neutrões e formação de imagens tomográficas por ultrassom. Pode-se afirmar, no entanto, que um dos mais proeminentes desenvolvimentos dessas técnicas de visualização de imagens médicas é sua adoção por outros campos das ciências, tais

como a tomografia industrial, aplicações para a obtenção de imagens por radar e imagens sísmicas.

Assim, como a demanda por imagens médicas aumentou desde o desenvolvimento dos equipamentos e da verificação de sua confiabilidade no diagnóstico, também aumentaram a demanda por imagens radiográficas na indústria e nos resultados que indicassem precisamente a existência de um defeito, pois um objeto industrial pode ser composto de uma larga variedade de complexos componentes. Portanto, para examinar o seu interior as ferramentas instrumentais (equipamento e *software*) e as técnicas deveriam ser adequadas a esse objetivo.

No contexto da Ciência da Computação, a tomografia tridimensional está ligada a uma área da computação gráfica denominada Visualização Científica (ViSC) [26]. A ViSC é a denominação formal que congrega técnicas que têm como objetivo prover uma melhor compreensão qualitativa de fenômenos científicos. O desenvolvimento de ferramentas computacionais, com o auxílio da computação gráfica, para a reconstrução de imagens tridimensionais aplicadas a sistemas de tomografia industrial, amplia a potencialidade de inspeção de um componente.

2.2 GERAÇÃO DE RAIOS X

Os raios X são produzidos quando um feixe de elétrons emitidos por um filamento de tungstênio (cátodo) é acelerado devido a uma diferença de potencial de alguns milhares de volts e este, colide com um alvo metálico (ânodo), o que causa a emissão de um espectro contínuo de radiação eletromagnética (fenômeno denominado de *bremssstrahlung*¹) e, também, um espectro característico de emissão que dependerá do material do alvo (emissão característica), com energia de milhares de elétrons-volts (eV) [27].

¹Expressão de origem alemã que denota a emissão de radiação por uma carga elétrica em desaceleração.




FIGURA 1 – ESQUEMA PARA FUNCIONAMENTO GERADOR DE RAIOS X. FONTE: ADAPTADO DE BUZUG [27].

A energia da radiação emitida depende da velocidade do elétron, v , o qual depende da tensão de aceleração aplicada entre o cátodo e o ânodo, eV . Então, de acordo com o princípio de conservação de energia, tem-se [28]:

$$eV = \frac{1}{2}m_e v^2 = K_1 \quad (2.1)$$

onde e é a carga do elétron, V é a diferença de potencial aplicada entre o cátodo e o ânodo, m_e é a massa do elétron, v a velocidade do elétron e K_1 é a energia cinética do elétron antes da colisão.

Na Figura 2 está ilustrado o processo elementar de produção de raios X. Um elétron de energia cinética inicial K_1 é desacelerado pela interação com um núcleo pesado no átomo que compõe o alvo. A energia que esse elétron perde aparece na forma de radiação como um fóton de raios X. A massa do núcleo em relação ao elétron é tão grande que a energia que ele adquire durante a colisão pode ser completamente desprezada. A energia E do fóton de raios X pode ser dada por

$$E = hf = K_1 - K_2 \quad (2.2)$$

onde h é a constante de Planck, f é a frequência da onda radiante, K_2 é a energia cinética do elétron após a colisão. Na Equação 2.2, fazendo $f = \frac{c}{\lambda}$, onde c é a velocidade da luz e λ é o comprimento de onda do fóton emitido, tem-se:

$$\lambda = \frac{hc}{K_1 - K_2} \quad (2.3)$$

O produto hc é igual a 12,4 keV. Assim, para λ dado em Å e E em keV, tem-se a Equação 2.4.

$$\lambda = \frac{12,4}{E} \quad (2.4)$$




FIGURA 2 - PROCESSO DE *BREMSSTRAHLUNG* (DESACELERAÇÃO DO ELÉTRON). FONTE: EISBERG E RESNICK [28].

A distribuição em energia da radiação produzida em um gerador de raios X é fundamental para permitir compreender os processos de produção da imagem radiográfica. O espectro de raios X é composto por duas partes distintas e superpostas: uma contínua e outra em linhas discretas. A parte contínua se deve aos raios X de *bremsstrahlung* e as linhas discretas ocorrem em decorrência dos raios X característicos (raios X devido ao processo de ionização dos átomos que compõe o alvo). Deve-se ressaltar que a maior parte da energia de colisão dos elétrons é dissipada na forma de calor no ânodo. Na Figura 3 está mostrado um espectro de raios X usado em radiodiagnóstico de acordo com CORREA [29].




FIGURA 3 - ESPECTRO ESQUEMÁTICO DE EMISSÃO DE RAIOS X PARA UM EQUIPAMENTO COM ALVO DE TUNGSTÊNIO. FONTE: ADAPTADO DE CORREA [29].

2.2.1 ATENUAÇÃO DOS RAIOS X PELA MATÉRIA

Quando o feixe de raios X atinge um material, sua intensidade diminui devido à interação dos fótons com a matéria. O feixe de raios X tem uma intensidade I e uma seção transversal de área A conforme mostra a Figura 4. No modelo, os átomos no material são idênticos e todos possuem seção transversal σ com uma densidade de n átomos por unidade de volume. Então, o número total de átomos encontrado pelo feixe de raios X é dado por An e a área ocupada pelos átomos no feixe incidente é $An\sigma$. Assim a probabilidade para que um fóton interaja com um átomo é $An\sigma/A = n\sigma$. A intensidade dos raios X removida numa espessura dx do material é [24]

$$dI = -n\sigma I dx \quad (2.5)$$

Rearranjando a equação anterior, fazendo $\mu = n\sigma$, que é fração de energia removida por unidade de espessura por unidade de intensidade e integrando obtém-se

$$I = I_0 e^{-\mu x} \quad (2.6)$$

onde I é a intensidade do feixe transmitido em x (espessura em cm), I_0 é a intensidade do feixe incidente no material, μ é definido como o coeficiente de

atenuação linear em cm^{-1} . A equação 2.6 é conhecida como a lei de Beer-Bauguer e é válida somente para radiações com feixes monoenergéticos [24].




FIGURA 4 - MODELO PARA FEIXE DE RAIOS X COM SEÇÃO TRANSVERSAL A ATINGINDO UM MATERIAL DE ESPESSURA X. FONTE: GODOI, 2005 [24].

2.2.2 RADIOSCOPIA INDUSTRIAL

A radioscopia é um meio usado na indústria para detectar a radiação que passa através da peça num intensificador de imagens. As telas desses intensificadores se baseiam no princípio que determinados sais (tungstato de cálcio, por exemplo) possuem a propriedade de emitir luz em intensidade mais ou menos proporcional a intensidade de radiação que incide sobre eles. Uma câmera de vídeo capta as imagens convertidas na tela do intensificador. Os sistemas de radioscopia convencionais geralmente são os mais utilizados dentro da planta de fábricas em cabines blindadas que protegem o operador da radiação. São encontrados também em equipamentos de inspeção de bagagens em aeroportos [1].

2.2.1 RADIOGRAFIA DIGITAL DIRETA INDUSTRIAL

Os sistemas de radiografia digital direta (*Digital Radiography* ou DR) são unidades compactas de aquisição de imagens radiográficas digitais (*flat panels*) que podem ser utilizadas em diferentes áreas, tais como, a radiologia convencional, odontológica, mamografia, fluoroscopia e indústria. Esse sistema gera as imagens radiográficas de forma direta, produzindo imagens digitais como no processo para se adquirir uma foto digital em câmeras pessoais, ou seja, não há necessidade de revelação ou *scanners* [24]. Atualmente existem detectores que operam na detecção de radiação com energias na ordem de MeV, o que possibilita ensaiar peças

bastante espessas. Os DRs ainda são limitados a poucas aplicações industriais e médicas devido ao alto custo. Na Figura 5 está mostrada a radiografia quatro isoladores poliméricos em um detector digital direto, com detector de a-Si, com 40 cm x 40 cm de campo de visão e 16 *bits* de resolução, utilizando os seguintes parâmetros de aquisição: 80 kV, 3 mA com 999 ms de exposição.




FIGURA 5 - RADIOGRAFIA DIGITAL DIRETA DE QUATRO ISOLADORES COM DEFEITOS EM UM DETECTOR MODELO XRD 1621 DO FABRICANTE *PERKIN ELMER*. FONTE: O AUTOR.

2.3 PROCESSAMENTO DIGITAL DE IMAGENS

O Processamento Digital de Imagens (PDI) consiste de um conjunto de técnicas para capturar, transformar e analisar imagens por meio de um sistema de aquisição (câmeras digitais, scanners, leitores de códigos de barras, sistemas de radiografias digitais, etc.). Atualmente, diversas áreas de conhecimento utilizam técnicas de processamento de imagens para a solução de demandas em medicina, biologia, automação industrial, astronomia e artes [30]. A metodologia para tal processamento pode ser subdividida em um conjunto de etapas: aquisição, pré-processamento, segmentação e extração de características (ou atributos) [24,31,32].

2.3.1 IMAGEM RADIOGRÁFICA DIGITAL

A imagem radiográfica digital consiste de uma matriz onde cada elemento, ou *pixel* (do inglês, *picture element*), é representado por um valor numérico em um tom de cinza [29,33]. Os detectores digitais utilizam a amostragem, que discretiza o domínio de definição da imagem nas direções x e y , gerando uma matriz de $M \times N$ amostras. A quantização consiste em escolher um número inteiro L de tons de cinza permitidos para cada ponto da imagem. Para uma imagem radiográfica digital, o valor do pixel $f(x, y)$ nas coordenadas (x, y) pode ser dado de acordo com a Equação 2.7

$$f(x, y) = i(x, y)t(x, y) \quad (2.7)$$

onde $0 \leq i(x, y) \leq I_{\max}$ é a intensidade de fótons incidentes no detector, I_{\max} intensidade máxima da fonte de radiação e $0 \leq t(x, y) \leq 1$ é a transmitância da fonte radiativa. O número de níveis de cinza da imagem $f(x, y)$ é normalmente é dado por $L = 2^b$, onde L é o número de tons de cinza da imagem e b é chamado de profundidade da imagem, por exemplo, $b=16$ bits na Figura 5 [30].

No domínio 3D, a amostragem e a quantização são representadas em coordenadas (x, y, z) , onde x, y, z correspondem ao espaço. Portanto, uma imagem digital tridimensional (ou imagem 3D) pode ser representada como uma sequência de imagens bidimensionais (2D) ao longo do eixo espacial z . Sendo as dimensões de um pixel nessas imagens $p \times p$ e o espaçamento entre os cortes d , a extensão ao do *pixel* em 3D define um pequeno paralelepípedo de dimensões $p \times p \times d$, compondo uma descrição geométrica que é formada por elemento de volume denominado *voxel* (*volume element*). Os *voxels* podem representar pontos de amostragem de fenômenos físicos e são usados para reconstruir no computador a forma ou função de estruturas tridimensionais [27].

2.3.2 PRÉ-PROCESSAMENTO DE IMAGENS DIGITAIS

Técnicas de processamento de imagens digitais buscam transformar uma imagem 2D ou 3D, de modo a torná-la mais adequada a uma aplicação específica. O processamento é necessário em casos de degradação da imagem original e perda de qualidade, assim como para realçar determinadas características e automatizar processos de decisão. As principais abordagens referentes às técnicas de processamento de imagens dividem-se em duas categorias: métodos no domínio

espacial e métodos no domínio de frequência. O domínio espacial refere-se ao próprio plano da imagem, e as abordagens nessa categoria são baseadas na manipulação direta dos pixels das imagens. Técnicas de processamento no domínio de frequência são baseadas na alteração das transformadas de Fourier das imagens.

2.3.3 SEGMENTAÇÃO DE IMAGENS DIGITAIS

A segmentação de imagens consiste na extração ou identificação de objetos de interesse, onde o objeto é toda região com informação semântica relevante para a aplicação desejada.

Limiarização é uma das primeiras técnicas de segmentação utilizadas em estudos de separação de objetos em imagens. Consiste na classificação dos pixels de uma imagem de acordo com a especificação de um ou mais valores (limiares) definidos pelo usuário. A imagem final pode ser rotulada, por exemplo, pixels rotulados como 1 (ou qualquer outro tom de cinza conveniente) corresponde aos objetos acima do limiar, enquanto que, aqueles rotulados como 0, correspondem ao fundo (background). Nesse caso, a limiarização é denominada binarização, pois o resultado do processo (imagem com rótulo binário) possui apenas dois valores de intensidade, 0 (preto) ou 1 (branco) [30].

Em casos onde a utilização de um único limiar não produz bons resultados na segmentação da imagem, a limiarização local adaptativa pode ser uma melhor alternativa. Uma forma de realizar a limiarização adaptativa é analisar as intensidades de tons de cinza dentro de uma janela local sobre a imagem para determinar limiares locais [30].

2.4 EXTRAÇÃO DE CARACTERÍSTICAS

Se uma imagem possuir todos os objetos bem definidos, é possível extrair informações que serão úteis para análises posteriores. Para a extração de características (ou atributos) é necessário definir descritores que contenham características que descrevam o objeto da imagem. Alguns descritores são encontrados na literatura, sendo classificados como descritores geométricos e topológicos [30].

Os descritores geométricos podem ser de borda e de região segmentada, por exemplo. Esses são algoritmos que adquirem características referentes à borda como, por exemplo, o perímetro de um objeto. Os descritores geométricos de regiões são algoritmos que adquirem características referentes à região interna do objeto, tais como, o volume de um objeto. Os descritores topológicos buscam características que levam em consideração a média dos tons de cinza [30].

2.5 TOMOGRAFIA COMPUTADORIZADA

O termo tomografia refere-se à imagem da secção transversal de um objeto, iluminado a partir de diferentes direções e à aquisição de um conjunto de dados que pode ser originado por processo de transmissão, reflexão ou emissão. O impacto dessa técnica no diagnóstico médico foi revolucionário, pois possibilitou a visualização de órgãos internos do paciente com precisão e segurança sem precedentes [34]. Assim TC tem se mostrado um indispensável método de imagem na rotina clínica. Foi o primeiro método não invasivo usado para adquirir imagens do corpo humano sem sobreposição das estruturas anatômicas distintas. Isso é devido à projeção de toda a informação numa imagem plana bidimensional, diferente das vistas em fluoroscopia de raios X. Além disso, imagens de TC possuem alto contraste comparado à radiografia convencional [27].

2.5.1 PROBLEMAS INVERSOS

A matemática da reconstrução de imagem em TC influenciou outros campos da ciência e vice-versa. A técnica de *backprojection*, por exemplo, é utilizada em geofísica e aplicações de radar. O problema fundamental da TC pode ser facilmente descrito: reconstruir um objeto a partir de suas “sombras” ou, mais precisamente, de suas projeções.

Grupos particulares de problemas matemáticos em TC tornaram-se populares nos anos 50 quando o astrofísico Bracewell provou que a resolução de telescópios poderia melhorar de forma significativa se a distribuição espacial dos telescópios fosse devidamente sincronizada [27].

Em tomografia computadorizada o termo problema inverso é imediatamente visível. A distribuição de atenuação espacial dos objetos que produzem a sombra de projeção não é conhecida *a priori*. Essa é uma das razões para adquirir as projeções

ao longo de uma coordenada de rotação do detector em intervalos angulares de projeção de pelo menos 180° [27].

Em 1961, a solução para esse problema foi aplicada pela primeira vez para uma sequência de projeções de raios X para o qual um objeto anatômico foi medido a partir de diferentes direções [27].

Conforme citado, os fundamentos da tomografia estão na reconstrução de uma imagem de um objeto por meio de suas projeções, sem conhecer o objeto em si. No termo estrito da palavra, uma projeção a um dado ângulo é uma função de distribuição da atenuação de um objeto na direção especificada por aquele ângulo, como ilustrado na Figura 6. Podem-se citar três tipos de projeções para os raios X: as de feixe paralelo, as de feixe em leque e as de feixe em cone [34].




FIGURA 6 - PRINCÍPIO DA TC. DUAS PROJEÇÕES EM DOIS ÂNGULOS DISTINTOS SÃO MOSTRADAS PARA UM OBJETO COMPOSTO DE DOIS CILINDROS. FONTE: KAK E SLANEY [34].

2.5.3 FORMAÇÃO DO TOMOGRAMA

A criação do tomógrafo computadorizado só foi possível devido a matemática desenvolvida especialmente para a tomografia. Graças ao matemático e médico Allan Cormack foi possível que o tomógrafo de Hounsfield viesse a se tornar realidade. Essa matemática permite que as informações “confusas” vindo dos sensores de raios X, que são semelhantes às imagens de uma radiografia

convencional, possam ser trabalhadas e dêem origem às imagens de cortes transversais da anatomia do paciente [27].

A tomografia, como conhecida hoje, além dos desenvolvimentos matemáticos, só foi possível devido ao desenvolvimento dos computadores. Como os computadores só foram disseminados a partir dos anos 80, existia a dificuldade computacional a ser resolvida. Assim, em 1977, Edholm introduz uma forma de configuração óptica para tomografia. O equipamento de Edholm funcionava da seguinte forma: para adquirir uma imagem, um feixe de raios X é produzido utilizando uma fenda de colimação, que irradia através do objeto e cuja projeção é gravada num filme como uma única linha. O filme é movido linearmente e de forma síncrona com a rotação do objeto examinado. O padrão gravado (linha a linha) é denominado senograma e pode ser usado para a reconstrução da tomografia em si. Depois de obtido o senograma segue-se para a reconstrução da imagem. O primeiro passo na reconstrução é uma iluminação unidimensional do senograma, que é projetado por uma lente de cilindros e gravada num segundo filme. As lentes cilíndricas espalham o perfil do senograma espacialmente (criando uma imagem sem resolução espacial, ou seja, borrada). Deslocando-se o filme do senograma e rotacionando as lentes cilíndricas simultaneamente, uma retroprojeção simples é armazenada e todos os perfis de projeções são superimpostos. Após isso, um filtro passa-alta é utilizado usando óptica de Fourier (lentes) para formar as fatias. Hoje, todo esse processo é feito digitalmente. Na Figura 7 está ilustrado o esquema de Edholm [27].




FIGURA 7 - PRINCÍPIO DA TOMOGRAFIA COMPUTADORIZADA: TOMOGRAFIA POR RECONSTRUÇÃO ÓPTICA DE EDHOLM. FONTE: BUZUG [27].

A imagem interna obtida ao final de uma reconstrução tomográfica representa a distribuição bidimensional dos coeficientes de atenuação dos objetos [35]. A tomografia por raios X utiliza como informação externa a atenuação de um feixe de raios X após atravessar um objeto (tomografia de transmissão). Ao atravessar o objeto ao longo de um determinado caminho reto, um feixe monocromático de raios X obedece à Lei de Lambert-Beer conforme a Equação 2.8 [32,34]

$$\int \mu(x, y) dx = \ln \frac{N_i}{N_d} \quad (2.8)$$

onde $\mu(x, y)$ é o coeficiente de atenuação no ponto (x, y) em cm^{-1} , N_i é o número de fótons que entram no objeto, N_d é o número de fótons que saem pelo objeto.

Ao atingir um material, a intensidade do fóton de raios X diminui devido à interação com o material. Assumindo que o feixe de raios X tem uma intensidade I e uma seção transversal de área A . Assumindo também que os átomos no material são idênticos e todos possuem seção de choque σ com uma densidade de n átomos por unidade de volume. Então o número total de átomos encontrados pelo feixe de raios X é dado por An e a área ocupada pelos átomos no feixe incidente é $An\sigma$. Assim, a probabilidade para que um fóton interaja com um átomo é $An\sigma/n\sigma$ como mostrado na Figura 8 [24,32,34].

A intensidade dos raios X removida numa espessura dx do material é dada pela Equação 2.9 [24,32,34]

$$dI = -n\sigma I dx \quad (2.9)$$

Fazendo $\mu = n\sigma$, na Equação 2.8, que é a fração de energia removida por unidade de espessura por unidade de intensidade e integrando, obtêm-se as Equações 2.10 e 2.11 [24,32,34].

$$I_y = I_0 e^{-\int_0^L \mu(x,y) dx} = I_0 e^{-\mu' L} \quad (2.10)$$

$$\mu = \frac{1}{L} \ln \left(\frac{I_0}{I_y} \right) \quad (2.11)$$

onde μ é o coeficiente de atenuação do material em um determinado ponto para uma determinada energia do feixe em (cm^{-1}), μ' é a somatória dos coeficientes de atenuação do material em um determinado ponto para uma determinada energia do feixe, I_0 é a intensidade do feixe que atinge o objeto, I_y é a intensidade do feixe de raios X após percorrer um determinado caminho pelo objeto e L é a espessura atravessada pelo feixe de raios X (em linha reta).

A intensidade I_y é proporcional ao número de fótons de raios X que atravessa todo o objeto como é mostrado nas Figuras 8 e 9.




FIGURA 8 - ATENUAÇÃO DA RADIAÇÃO EM RELAÇÃO À ESPESSURA DE UM OBJETO ANALISADO NAS EQUAÇÕES 2.7 E 2.8. FONTE: RIBEIRO-JÚNIOR [32].




FIGURA 9 - ATENUAÇÃO DA RADIAÇÃO EM RELAÇÃO À ESPESSURA DE UM OBJETO. FONTE: ADAPTADO DE RIBEIRO-JÚNIOR [32].

A projeção dada por I_y é conhecida, em geral, como uma projeção $P\phi(r)$. Ela é definida pela transformada de Radon, como:

$$P\phi(r) = \int_{\phi, r} f(x, y) ds \quad (2.12)$$

onde (ϕ, r) representam as coordenadas da trajetória percorrida por um fóton de raios X.

O sistema de coordenadas (r, j) mostrado na Figura 10 corresponde à rotação do par de eixos (x, y) de um ângulo ϕ demonstrado na Equação 2.13.




FIGURA 10 - PARÂMETROS PARA PROJEÇÃO DE UMA IMAGEM DE RAIOS X. FONTE: RIBEIRO-JÚNIOR [32].

$$\begin{bmatrix} r \\ j \end{bmatrix} = \begin{bmatrix} \cos\phi & \sin\phi \\ \sin\phi & -\cos\phi \end{bmatrix} = \begin{bmatrix} x \\ y \end{bmatrix} \quad (2.13)$$

Utilizando as equações 2.12 e 2.13 relativas à r ($r = x\cos\phi + y\sin\phi$), pode-se escrever a projeção $P(\phi, r)$ conforme descrito na Equação 2.14

$$P(\phi, r) = \iint_{-\infty}^{+\infty} f(x, y) \delta(x\cos\phi + y\sin\phi - r) dx dy \quad (2.14)$$

onde $t = t(\varphi, r)$. A Equação 2.14 é conhecida como a Transformada de Radon da função $f(x, y)$ utilizando a distribuição delta de Dirac. A distribuição delta de Dirac é um objeto matemático definido para fazer o papel da identidade para a operação de convolução de funções. A distribuição δ torna mais fácil a unificação do tratamento do estudo de Séries de Fourier e Transformadas de Fourier. Fisicamente, ela pode ser interpretada como um impulso de energia em um sistema, razão pela qual recebe o nome de Função Impulso de Dirac.

2.5.4 PROJEÇÕES DE FEIXE EM LEQUE E CONE

Na evolução da construção dos tomógrafos, os aperfeiçoamentos levaram ao aparecimento da 3ª geração de equipamentos, onde o feixe de raios X emitido possui uma abertura muito ampla. Opostamente à fonte emissora, uma linha de 200 a 1000 detectores dispostos em ângulo recebe a radiação após esta penetrar todo o material a ser analisado. Os tempos de processamento desses equipamentos estão na faixa entre 1 e 4 s por corte. São os mais utilizados atualmente devido a sua relação custo/benefício.

Na projeção de feixe em cone, bem como em leque, os feixes partem do mesmo ponto, mas há uma divergência tridimensional formando um cone. Neste caso, o detector deverá ser plano, como mostrado na Figura 11.




FIGURA 11- SISTEMA DE DETECÇÃO DE FEIXE EM LEQUE DE ROTAÇÃO COM DETECTORES MÓVEIS. FONTE: RIBEIRO-JÚNIOR [32].

As radiografias nas projeções dos tomógrafos de 3ª geração utilizando fontes de raios X são obtidas pela rotação do sistema fonte-detector, ou apenas pela rotação do objeto. A fonte emite feixes de raios X, que atravessarão o objeto por caminhos distintos, apresentando cada feixe uma atenuação diferente. Os feixes atingem o detector em uma determinada posição, gerando assim uma projeção $P(\varphi, r)$. Em seguida o objeto é rotacionado de um ângulo $d\varphi$ e novamente radiografado como mostrado na Figura 11. As projeções são utilizadas no processo de reconstrução de imagens tomográficas 2D e 3D. Em alguns casos a reconstrução das tomografias utiliza a projeção em leque ou cone. Dessa forma, é necessário realizar a correção do feixe para evitar algumas distorções da imagem tomográfica, as quais podem trazer alterações na avaliação das imagens tomográficas 2D e 3D [32].

A reconstrução das tomografias utilizando a projeção paralela é mais simples pois a imagem projetada se altera com relação a sua dimensionalidade.

Para feixes em cone, é conveniente que a distância entre a fonte de raios X e o objeto seja muito maior que a distância do objeto ao detector. Dessa forma, os feixes serão aproximadamente paralelos. Para obter melhores resultados é possível prever o caminho percorrido pelos feixes cônicos eliminando assim ampliações e distorções nas reconstruções tomográficas.

2.5.5 RECONSTRUÇÃO TOMOGRÁFICA POR RETROPROJEÇÃO SIMPLES

A retroprojeção simples é uma técnica de reconstrução tomográfica que pode ser vista como o caminho inverso da projeção. Para isso é utilizado o operador retroprojeção definido na Equação 2.15.

$$f(x, y) = \int_0^\pi P(x \cos \varphi + y \sin \varphi, \varphi) d\varphi \quad (2.15)$$

A retroprojeção simples consiste em integrar cada uma das linhas adquiridas em cada projeção por todo o caminho realizado pelo feixe, cobrindo assim toda a imagem, na direção do respectivo ângulo da projeção.

De uma maneira geral, para reconstruir tomografias com esse método, obtém-se a primeira linha da primeira projeção, conforme mostrado na Figura 10, depois a primeira linha da segunda projeção, e assim, consecutivamente até a última projeção. Realizam-se as mesmas etapas para a segunda, terceira até a última

linha. Para a primeira linha de todas as projeções, empilhadas, define-se uma imagem denominada senograma da primeira linha, para a segunda, define-se uma imagem senograma da segunda linha e assim consecutivamente até a última linha. O senograma é uma imagem bidimensional, na qual se representa em um eixo a atenuação dos fótons e no outro a posição angular do detetor. Na Figura 12 está mostrada, esquematicamente, o princípio das projeções e a representação do senograma. Para a reconstrução da tomografia aloca-se memória em uma matriz vazia, com dimensões $M \times M$, onde serão retroprojetadas as informações armazenadas nos senogramas.




FIGURA 12 - SENOGRAMA DE UMA TOMOGRAFIA INDUSTRIAL. FONTE: ADAPTADO DE RIBEIRO-JÚNIOR [32].

2.5.6 RECONSTRUÇÃO TOMOGRÁFICA POR RETROPROJEÇÃO FILTRADA

Na reconstrução de imagens tomográficas por retroprojeção simples é possível visualizar imagens resultantes, mas com pouca nitidez. Sendo assim, é necessário aplicar filtros no processo, e por isso, esta é definida como retroprojeção filtrada. Essa técnica visa melhorar a nitidez das imagens mediante a aplicação de filtros. RIBEIRO-JÚNIOR [32] ilustrou o processo de reconstrução tomográfica, por meio da técnica de retroprojeção filtrada, de acordo com o fluxograma na Figura 13.




FIGURA 13 - FLUXOGRAMA PARA SISTEMA DE DETECÇÃO EM PARALELO DE ROTAÇÃO-TRANSLAÇÃO SIMPLES. FONTE: ADAPTADO DE RIBEIRO-JÚNIOR [32].

O filtro Ram-Lak, também conhecido como filtro rampa, Equação 2.16, apresenta como característica o realce de componentes de alta frequência, dentro do limiar estabelecido, como mostrado na Figura 14.

$$H_{RL}(\xi, \varphi) = \frac{2(\xi, \varphi)\pi}{n} \quad (2.16)$$

onde $H_{RL}(\xi, \varphi)$ é o valor do filtro Ram-Lak utilizado no domínio de frequência de Fourier, (ξ, φ) é o intervalo do sinal com que será realizado o filtro e n é o número de pontos da imagem.




FIGURA 14 - CARACTERÍSTICA DO FILTRO RAM-LAK: (A) RESPOSTA NO DOMÍNIO DE FREQUÊNCIA E (B) RESPOSTA EM DOMÍNIO ESPACIAL. FONTE: ADAPTADO DE KAK E SLANEY [34].

O filtro Shepp-Logan, demonstrado na Equação 2.17, apresenta atenuação maior do que os filtros retangulares com resposta de frequência menos abrupta na zona de transição, como está demonstrado na Figura 15.

$$H_{SL}(\xi, \varphi) = abs(H_{RL}(\xi, \varphi)) \frac{\frac{sen(H_{RL}(\xi, \varphi))}{\frac{n}{H_{RL}(\xi, \varphi)} - k}}{\frac{n}{H_{RL}(\xi, \varphi)} - k} \quad (2.17)$$

onde k é o fator de ajuste do filtro Shepp-Logan, $H_{SL}(\xi, \varphi)$ é o valor do filtro Shepp-Logan utilizado no domínio de frequência de Fourier.




FIGURA 15 - CARACTERÍSTICA DO FILTRO SHEPP-LOGAN: (A) RESPOSTA NO DOMÍNIO DE FREQUÊNCIA E (B) RESPOSTA EM DOMÍNIO ESPACIAL. FONTE: ADAPTADO DE HERMAN [36].

O filtro Hanning, demonstrado na Equação 2.18, apresenta atenuação maior do que os filtros retangulares com resposta de frequência menos abrupta na zona de transição, como é demonstrado na Figura 16.

$$H_{HN}(\xi, \varphi) = H_{RL}(\xi, \varphi) (\beta + (1 - \beta) \cos(H_{RL}(\xi, \varphi))) \quad (2.18)$$

onde β é o fator de ajuste do filtro Hanning, $H_{HN}(\xi, \varphi)$ é o valor do filtro Hanning utilizado no domínio de frequência de Fourier.




FIGURA 16 - CARACTERÍSTICA DO FILTRO HANNING: (A) RESPOSTA NO DOMÍNIO DE FREQUÊNCIA E (B) RESPOSTA EM DOMÍNIO ESPACIAL. FONTE: ADAPTADO DE HERMAN [36].

O filtro Hamming, demonstrado na Equação 2.19, apresenta uma ondulação (*ripple*) menor do que os filtros retangulares e, também, apresenta uma maior atenuação do que o filtro Shepp-Logan com resposta de frequência menos abrupta na zona de transição, como está demonstrado na Figura 17.

$$H_{HM}(\xi, \varphi) = \text{abs}(H_{RL}(\xi, \varphi)r)((0,5 + \alpha) + ((0,4 + \alpha) \cos\left(\frac{2\pi(\xi, \varphi)}{n}\right) + (0,08 \cos\left(\frac{4\pi(\xi, \varphi)}{n}\right))) \quad (2.19)$$

onde r é o fator de ajuste de contraste; α é o fator de ajuste do filtro Hamming, $H_{HM}(\xi, \varphi)$ é o valor do filtro Hamming utilizado no domínio de frequência de Fourier.




FIGURA 17 - CARACTERÍSTICA DO FILTRO HAMMING. FONTE: KAK E SLANEY [34].

2.5.7 TOMOGRAFIA INDUSTRIAL

A TC industrial tem inúmeras aplicações nas quais permite a reconstrução de objetos em diferentes formas e densidades [37]. Essa técnica possibilita inspecionar o interior de componentes manufaturados na busca de defeitos, podendo ainda apontar falhas em processos inadequados de produção. A TC industrial tem sido amplamente utilizada em diversas aplicações industriais. Nesta seção faz-se um levantamento de trabalhos que envolvem a tomografia no campo de aplicação industrial.

LU *et al.*, [38] mostraram aplicações da microtomografia por raios X no estudo de poros e permeabilidade em concreto.

SALVO *et al.* [39] mostrou aplicações de microtomografia 2D e 3D para caracterização de alumínio com a utilização de resoluções na ordem de 1 a 2,5 μm e técnica de contraste de fase.

LUGGAR *et al.* [40] mostrou aplicações da microtomografia de feixe cônico, para análises quantitativas e visualização de dados volumétricos de alta resolução

(abaixo de 100 μm) e a tomografia de raios X de alta velocidade, de interesse da indústria para inspeções em processos envolvendo fluidos.

Existem aplicações da tomografia na indústria de alimentos. HIRAKIMOTO *et al.* [41] desenvolveram uma aplicação para verificar a potencialidade da microtomografia na análise de um tipo de cereal matinal, com intuito de verificar sua estrutura volumétrica (vazios intersticiais). CHAUNIER [42] utilizou a tomografia industrial por raios X para analisar a microestrutura de cereais matinais que passaram por extrusão como pétalas em seu processo de cozimento, um dos parâmetros de grande interesse na indústria de alimentos.

BRUNETTI *et al.* [43] relataram aplicações de tomografia de raios X para visualização do comportamento de monômeros e polímeros em pedras porosas, tais como concreto, que estão sujeitas à penetração de líquidos, o que pode prejudicar a estrutura desses materiais. Assim, uma análise sobre o polímero é importante, pois ele pode ser utilizado para ambos os casos, consolidação estrutural e conservação.

BORD *et al.* [44] relataram aplicações de tomografia em microeletrônica, para inspeção de componentes, tais como trilhas e soldas eletrônicas. Os autores descreveram um novo sistema de tomossíntese micro-3D, combinado com a tecnologia dos sistemas de alta resolução de raios X utilizando gerador microfoco e o estado da arte das possibilidades da reconstrução 3D. É ideal para a análise de novas aplicações em microeletrônica, como os empacotamentos de semicondutores.

Uma área crescente na aplicação de tomografia no setor industrial é denominada nanotomografia por raios X [45]. Já existem equipamentos comerciais para aplicações em ciências dos materiais [46].

Outros exemplos de aplicação de tomografia bi e tridimensional na indústria podem ser vistos no livro editado por PRABHAT MUNSHI [25] intitulado “*Computerized Tomography for Scientists and Engineers*”. MUNSHI cita aplicações de tomografia industrial para líquidos bifásicos ou com multifases, aplicações na detecção de vazios em cilindros de alumínio, tomografia em pesquisas de fusão a plasma e líquidos bifásicos com alta densidade.

DARLING *et al.* [47] concluíram em seu trabalho que é possível fazer caracterização de polímeros para aplicações em bioengenharia por microtomografia

3D. Para isso foi realizada a correlação dos resultados das imagens de tomografia 2D e 3D de polímeros tipo policaprolactona (PCL) produzidos com diferentes parâmetros de processamento e microarquiteturas com ensaios de laboratório. As aquisições de imagens foram realizadas por um equipamento de microtomografia de 19,1 μm de resolução, o que permitiu analisar o aspecto microestrutural das amostras.

Uma das preocupações existentes no transporte de óleo refinado é o risco de acidentes. Existem estudos para se produzir esponjas capazes de absorver esse óleo retirando-o do solo ou da água de maneira eficiente. DUONG e BURFORD [48] examinaram o efeito do comportamento de absorção de óleo em quatro esponjas de poliuretano utilizando microtomografia, observando o transporte do óleo entre os poros das esponjas pela técnica.

MONTEIRO *et al.* no livro editado por SKALNY e MINDESS [49], mostraram aplicações da TC em concreto reforçado com fibras como metodologia de END, utilizando tomografia por raios X e por micro-ondas. O trabalho consistiu em determinar trincas e localizar precisamente barras metálicas em amostras de 13,5 cm x 15 cm x 9 cm.

Alguns trabalhos em tomografia industrial, envolvendo a concepção de metodologias, *software* e instrumentação, têm sido desenvolvidos no Instituto de Tecnologia para Desenvolvimento (LACTEC), em Curitiba. Nesse sentido, podem-se citar os trabalhos de QUOIRIN [50], que utilizou tomografia para estudo de defeitos em amostras de madeira de interesse industrial (*pinus* e eucalipto), PIEKARZ [31], que desenvolveu métodos de quantificação de volumes por tomografia de raios X dos vazios em isoladores poliméricos utilizados em linhas de distribuição de energia, RIBEIRO-JÚNIOR [32], que utilizou tomografia 2D e 3D em análise da ruptura dielétrica em materiais isolantes elétricos de cabos isolados XLPE e EPR e MENDES [51] que aplicou a técnica de tomografia para estudo de testemunhos de concreto retirados de uma barragem hidroelétrica.

2.6 VISUALIZAÇÃO CIENTÍFICA E VOLUMÉTRICA

Segundo PAIVA *et al.* [52] visualização científica e volumétrica é um termo relacionado aos métodos que permitem a extração de informações relevantes a partir de conjuntos de dados, utilizando técnicas de computação gráfica e

processamento de imagens. Caracteriza-se visualização científica quando esses conjuntos de dados representam fenômenos complexos e o objetivo é a extração de informações científicas relevantes. A visualização volumétrica é uma classe de métodos relacionada com a representação, manipulação e visualização de conjuntos de dados volumétricos.

Os algoritmos de reconstrução de uma imagem tomográfica tridimensional objetivam a extração de superfícies ou volumes.

De acordo com LORENSEN e CLINE [53] a reconstrução de imagens tomográficas médicas 3D consiste das seguintes etapas:

1. aquisição dos dados, onde são obtidas múltiplas fatias 2D (*slices*).
2. processamento digital de imagens, onde encontram-se estruturas na imagem 3D.
3. possibilidade de usar filtros tridimensionais como o filtro gaussiano ou o filtro da mediana com o objetivo de suavização da superfície reconstruída.
4. construção da superfície, onde é criado um modelo de superfície a partir dos dados 3D, utilizando *voxels* ou polígonos, especificando a superfície desejada por um parâmetro de densidade que caracteriza o material pelo usuário.
5. visualização (*display*), que consiste em mostrar a superfície criada com cor, textura e iluminação (*shading*).

A reconstrução tomográfica 3D, em aplicações industriais, seguem as mesmas etapas definidas anteriormente por LORENSEN e CLINE [53].

Atualmente, devido aos avanços de algoritmos e hardware, podem-se obter tomografias tridimensionais de órgãos e estruturas. Esse tipo de tomografia transformou-se em ferramenta de diagnóstico médico, pois, ao invés de se observar apenas um corte transversal de um órgão de paciente, pode-se visualizar todo o órgão na tela do computador e fazer um diagnóstico mais preciso. Em aplicações industriais, a tomografia tridimensional também tem alcançado importância com diversas aplicações como na inspeção de defeitos com maior precisão.

Uma área ativa da Computação Gráfica é a Visualização Científica (ViSC), que propicia a análise visual e a exploração de dados decorrentes da natureza ou do processamento científico. Seu intuito maior é proporcionar recursos para o

tratamento de grandes volumes de dados procurando organizá-los visualmente de modo que o observador possa deles apreender informações científicas relevantes. Atualmente, a ViSC tem sido aplicada em várias áreas do conhecimento tais como: na cartografia, geologia, bioquímica, meteorologia, indústria e medicina [54].

Um modo de apresentar um conjunto de seções transversais (tomografias 2D) como um objeto 3D é reconstruí-lo por meio do empilhamento dessas fatias e interpretá-las como um objeto tridimensional (Figura 18). Assim, um volume é formado a partir do empilhamento. O algoritmo de reconstrução deverá conectar corretamente os *pixels* de mesma densidade das fatias adjacentes. Isso é feito a partir de técnicas de computação gráfica para a criação de imagens pela projeção em uma superfície bidimensional tal como a tela do computador [55]. Nesta seção, estão apresentadas as técnicas de visualização mais utilizadas para a reconstrução de tomografias 3D.




FIGURA 18 - ETAPAS PARA A RECONSTRUÇÃO DE UMA TOMOGRAFIA 3D: (A) PROJEÇÕES E (B) RECONSTRUÇÃO TOMOGRÁFICA 2D E 3D. FONTE: ADAPTADO DE SOUZA [55].

2.6.1 ALGORITMOS DE EXTRAÇÃO DE SUPERFÍCIES

Em aplicações em tomografia, o algoritmo de extração de superfícies visa representar, por um limiar escolhido pelo usuário, apenas a superfície que representa a fronteira entre o que está acima e o que está abaixo do seu valor. Nas aplicações industriais escolhe-se um valor associado à superfície de um dado material entre os presentes na amostra de ensaio. Na Figura 19, está ilustrado o algoritmo *Contour Connecting* para três fatias. Um dos mais utilizados pelas

ferramentas computacionais é o algoritmo de *Marching Cubes*, de LORENSEN e CLINE [53,56].




FIGURA 19 - ALGORITMO CONTOUR CONNECTING PARA TRÊS FATIAS TOMOGRÁFICAS.
FONTE: SOUZA [55].

O algoritmo de *Marching Cubes* (ou Cubos Marchantes) foi apresentado por LORENSEN e CLINE [56] em dezembro de 1987 nos Estados Unidos para a empresa GE.

O algoritmo de *Marching Cubes* baseia-se em dois passos: (i) localização da superfície correspondente ao valor especificado como parâmetro e; (ii) cálculo das normais nos vértices dos triângulos, a fim de criar uma superfície de alta qualidade visual. O *Marching Cubes* utiliza a técnica de divisão e conquista (*divide and conquer*) para localizar a superfície a partir de um cubo lógico, formado por oito pixels (quatro para cada fatia adjacente). Cada *pixel* é representado por um vértice do cubo [53,56].

O algoritmo determina o modo como a superfície faz intersecção com o cubo, movendo-se (ou “marchando”) então para o próximo cubo. Para verificar se a superfície faz intersecção com o cubo, o algoritmo determina se o valor do vértice escolhido excede ou equivale ao valor da superfície a ser construída. Caso seja verdadeiro, o vértice recebe valor um, indicando que está dentro da superfície. Caso contrário, o vértice recebe valor zero, indicando que está fora. Assim, por meio da localização dessas intersecções, é possível determinar a topologia de uma superfície dentro de um cubo por meio de triangulações. Podem-se enumerar 256 diferentes situações para a representação de superfícies por *Marching Cubes*. Por rotações e simetrias, todos os casos podem ser reduzidos a 15 famílias. Na Figura 20 estão ilustrados os 15 casos [53,56].




FIGURA 20 - TABELA ORIGINAL DO *MARCHING CUBES*. FONTE: LORENSEN E CLINE [53].

O algoritmo resultará, em geral, num considerável número de triângulos para formar as superfícies geradas. Esses triângulos, apresentados em malhas, determinam a qualidade e o tempo de processamento do modelo geométrico. Porém, as malhas que apresentam um número elevado de triângulos não podem ser geradas para aplicações em tempo real. Assim, deve-se reduzir o número de polígonos. A técnica de *Decimation* foi desenvolvida a fim de solucionar esse problema. O *Decimation*, proposto por SCHROEDER *et al* [57], é também conhecido como redução de polígonos ou simplificação de malha. Trata-se de um processo que reduz o número de triângulos em uma malha, preservando o tanto quanto possível as suas características.

Na Figura 21, apresentam-se duas imagens para comparação entre o algoritmo *Contour Connecting* e *Marching Cubes*. Nota-se a resolução melhorada na Figura 21b.

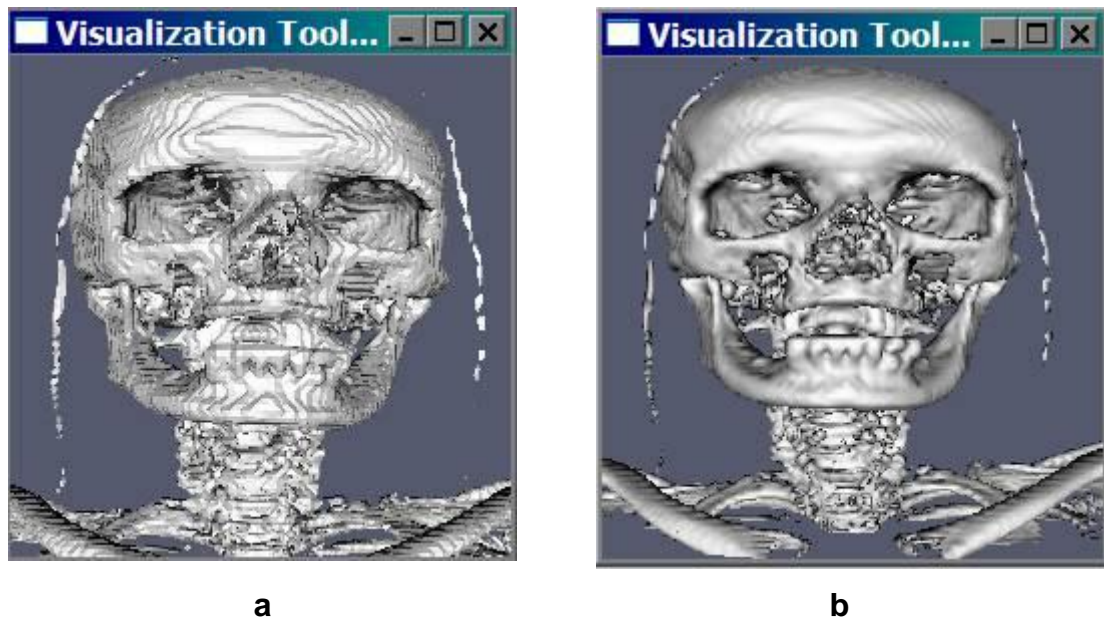


FIGURA 21 - RENDERIZAÇÃO POR: (A) CONTOUR CONNECTING E (B) MARCHING CUBES.
FONTE: VTK [58].

2.6.2 ALGORITMOS DE RENDERIZAÇÃO DE VOLUMES

Existem quatro abordagens básicas para o problema de renderização direta de volumes: (i) ordem da imagem (*forward mapping*), (ii) ordem dos objetos (*backward mapping*); (iii) métodos baseados em mudança de base e; (iv) métodos baseados em transformações geométricas do volume [52].

Na primeira abordagem, geralmente lança-se um raio associado a cada *pixel* da imagem e encontram-se os *voxels* interceptados, os quais contribuem para o valor do *pixel* (Figura 22a). Na abordagem baseada na ordem dos objetos, percorre-se o volume e, para cada *voxel*, encontram-se os *pixels* que são afetados pela sua contribuição (Figura 22b).




FIGURA 22 - MODELOS PARA RENDERIZAÇÃO DE VOLUMES: (A) ESPAÇO DA IMAGEM (PROCESSA VÁRIOS VOXELS PARA DEFINIR UM PIXEL NA TELA) E (B) ESPAÇO DO OBJETO (PROCESSA UM VOXEL PARA COMPUTAR ALGUNS PIXELS NA TELA). FONTE: ADAPTADO DE PAIVA ET AL. [52].

Técnicas de renderização de volumes geram uma imagem do volume diretamente a partir dos dados volumétricos. Todo o volume é representado na tela do computador e reconstruído de uma única vez, sem etapas intermediárias. Aplicações envolvem objetos amorfos, tais como tumores, vasos, fluidos e outros tecidos humanos. Existe a desvantagem de se percorrer todo o volume sempre que se muda um parâmetro como, por exemplo, a posição ou orientação. Exemplos de algoritmos que renderizam volumes são o *Bresenham* [59] e o *tripod* [60] (Figura 23). Um dos algoritmos mais utilizados para a visualização de volumes, quando se necessita de imagens de alta qualidade é o *Ray Casting* [61]. Este algoritmo implementado na ferramenta computacional desenvolvida neste trabalho.




FIGURA 23 - COMPARAÇÃO ENTRE DOIS ALGORITMOS PARA RECONSTRUÇÃO DE VOLUME. À ESQUERDA VOLUME RECONSTRUÍDO PELO ALGORITMO DE *BRESENHAM* E À DIREITA PELO ALGORITMO DE *TRIPOD*. FONTE: PAIVA ET AL. [52].

O algoritmo *Ray Casting* teve como uma de suas primeiras aplicações a renderização das paredes fixas do ambiente de um jogo 3D de computador em 1992 (chamado *Wolfenstein 3D* ou *Wolf 3D*). Foi um dos primeiros trabalhos a utilizar a ideia do lançamento de raios para visualizar cenas como proposto por APPEL [62]. Assim, este acabou sendo um dos paradigmas mais difundidos em visualização. A ideia é simples: (i) lançar raios de visão a partir do ponto de vista do observador da cena, em direção ao espaço dos objetos; (ii) determinar a primeira intersecção entre cada raio e um desses objetos; (iii) determinar a cor correta do objeto naquele ponto, e (iv) utilizar essa cor para a exibição da imagem na tela, no ponto em que a tela também é interceptada pelo raio. Na Figura 24 está ilustrado o modelo de funcionamento do algoritmo *Ray Casting*.




FIGURA 24 - MODELOS PARA RENDERIZAÇÃO DE VOLUMES POR *RAY CASTING*. FONTE: PAIVA [52].

O algoritmo para uma versão básica do de *Ray Casting* está apresentado a seguir.

Algoritmo 1 - Algoritmo *Ray Casting*.

```

for cada pixel do
    lança um raio em direção ao volume
    while existem voxels no caminho do
        acumula cor e opacidade
        avança para o próximo voxel
    end while
end for

```

Geralmente, utiliza-se um raio para cada *pixel* e cada raio passa pelo centro do *pixel* (amostragem pontual descrita por FOLEY [59]). Entretanto, há variações que utilizam mais de um raio por *pixel* (super-amostragem), para melhorar a qualidade da imagem, evitando efeito de serrilhado nas bordas ou simulando características físicas de lentes. Outras técnicas tentam simular raios que não sejam exatamente lineares, isto é, sem espessura, mas sim entidades geométricas com volume (cones, prismas, etc.) e que, como tal, interceptam uma certa área de cada *pixel*, podendo melhorar a amostragem (amostragem por área) e a qualidade da cena.

2.7 RECONHECIMENTO DE PADRÕES UTILIZANDO REDES NEURAIAS

O ato de reconhecer uma pessoa em uma foto, saber qual é a chave do carro no bolso apenas pelo toque, diferenciar o gosto do café de um chá, ou mesmo um café forte de um café fraco, diferenciar o cheiro de uma boa comida e saber qual é o prato do dia, ou o ato de ler uma carta apesar de parecerem simples aos seres humanos requerem um processo de reconhecimento de padrões. O sucesso desse reconhecimento de padrões é devido à nossa experiência (aprendizagem). Muitas dessas habilidades podem ser reproduzidas pelo uso de uma máquina. Assim, construir máquinas capazes de imitar essas habilidades em reconhecimento de padrões atendem diversas demandas, por exemplo: (i) ligar para um amigo utilizando o reconhecimento por voz em telefones celulares; (ii) as aplicações em biometria (como o reconhecimento de impressões digitais em controle de acessos ou registros de entradas e saídas de funcionários); (iii) uso do OCR (*Optical Character Recognition*) do *scanner* em um simples ato de armazenar um texto

impresso e; (iv) a facilidade de realizar o pagamento das compras com os leitores de código de barras em supermercados [63].

2.7.1 PADRÃO DE UMA CLASSE

Um padrão é uma descrição quantitativa ou estrutural de um objeto, ou de outra entidade de interesse em uma imagem ou em um sinal. Um padrão é, em geral, composto por um ou mais descritores, frequentemente conhecidos como características. Uma classe de padrões pode ser considerada como uma família de padrões que compartilhem algumas propriedades comuns [30].

O reconhecimento de padrões por máquinas envolve técnicas para atribuição dos padrões as suas respectivas classes. Para representar os padrões, utiliza-se normalmente a representação vetorial, sendo que em alguns casos emprega-se também a representação em cadeias e árvores, usadas para descrições estruturais [30]. Normalmente, um vetor de um padrão é representado por um vetor linha conforme,

$$\vec{x} = (x_1, x_2, x_3, \dots, x_n) \quad (2.20)$$

onde x_i representa cada componente, ou seja, a i -ésima característica, e n é o número de características. O seu vetor transposto também pode ser usado [30].

Para ilustrar o conceito de padrão e classe, considere-se um exemplo publicado por FISHER [64] para demonstrar a técnica de “Análise Discriminante Linear”. Há nos dados de Fisher 150 observações de cada um dos seguintes tipos de flores: (i) iris-setosa, (ii) iris-versicolor e; (iii) iris-virginica. As características levantadas por Fisher foram:

- F1: comprimento da sépala (cm)
- F2: largura da sépala (cm)
- F3: comprimento da pétala (cm)
- F4: largura da pétala (cm)

Para FISHER [64], um sistema poderia ser capaz de identificar tipos de flores de forma automática. Para isso, o sistema teria como entrada duas informações: largura e comprimento da pétala (vetor padrão representado por x_1 e x_2).

Na Figura 25 está mostrada como fica a separação no espaço 2D das medidas levantadas e a possibilidade de criar um classificador capaz de separar os três tipos de classes em questão (flores). Pode-se ver a distinção das classes apenas utilizando esses dois atributos. A massa de dados conhecida como “Iris” é provavelmente o exemplo mais famoso na literatura de reconhecimento de padrões.

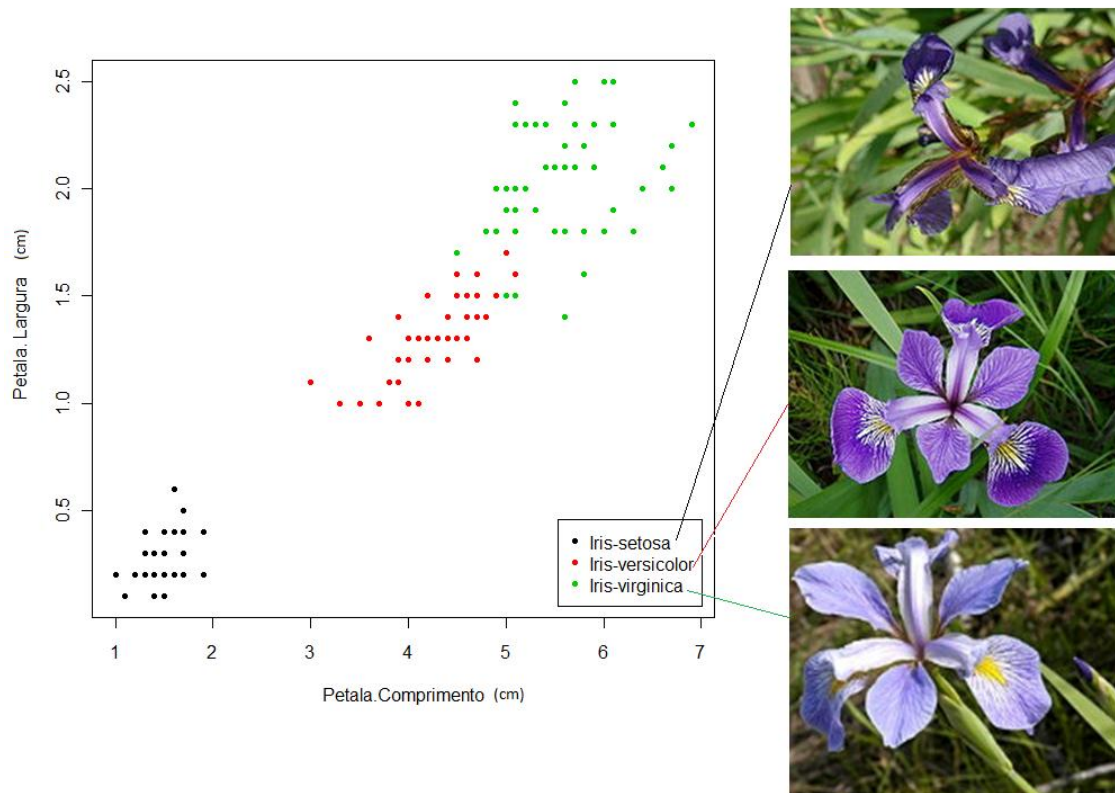


FIGURA 25 - EXEMPLO DE DISTRIBUIÇÃO DE CLASSES PARA DADOS “IRIS” DE FISHER [64]. O GRÁFICO ILUSTRA TRÊS TIPOS DE CLASSES (OU SEJA, TRÊS TIPOS DE FLORES) QUE PODERIAM SER SEPARADAS POR UM CLASSIFICADOR APENAS COM O LEVANTAMENTO DE DUAS CARACTERÍSTICAS: COMPRIMENTO E LARGURA DE PÉTALAS. FONTE: ADAPTADO DE FISHER [64].

2.7.2 REDES NEURAIS ARTIFICIAIS

O sistema nervoso é formado por um conjunto extremamente complexo de células, os neurônios. Eles têm um papel essencial na determinação do funcionamento e comportamento do corpo humano e do raciocínio. Os neurônios são formados pelos dendritos e axônios. Os dendritos são um conjunto de terminais de entrada, pelo corpo central. Os axônios são longos terminais de saída. Os neurônios se comunicam pelas sinapses, que são os pontos de contato pelos quais

os impulsos nervosos são transmitidos. Os impulsos recebidos por um neurônio A, em um determinado momento, são processados, e, ao atingirem um dado limiar de ação, fazem com que o neurônio A produza uma substância neurotransmissora que flui do corpo celular para o axônio. O axônio pode estar conectado a um dendrito de um outro neurônio B. O neurotransmissor pode diminuir ou aumentar a polaridade da membrana pós-sináptica, inibindo ou excitando a geração dos pulsos no neurônio B. Esse processo depende de vários fatores, como a geometria da sinapse e o tipo de neurotransmissor. Em média, cada neurônio forma entre mil e dez mil sinapses [65].

Redes Neurais Artificiais (RNA) são técnicas computacionais que apresentam um modelo matemático inspirado na estrutura neuronal de organismos inteligentes e que adquirem conhecimento por meio da experiência. Uma grande rede neural artificial pode ter centenas ou milhares de unidades de processamento; já, o cérebro de um mamífero pode ter bilhões de neurônios. Elas foram inicialmente propostas por MCCULLOCH e PITTS [66], HEBB [67] e ROSENBLATT [68], que introduziram o primeiro modelo de rede neural simulando máquinas, o modelo básico de rede de auto-organização e o modelo *Perceptron* de aprendizado supervisionado. HOPFIELD [69] relatou a utilização de redes simétricas para otimização. RUMELHART *et al* [70] introduziram o método *backpropagation*. Entretanto, para se ter um histórico completo, devem ser citados alguns pesquisadores que realizaram, nos anos 60 e 70, importantes trabalhos sobre modelos de redes neurais em visão, memória, controle e auto-organização como [65]: Amari, Anderson, Cooper, Cowan, Fukushima, Grossberg, Kohonen, Von der Malsburg, Werbos e Widrow.

Uma rede neural artificial é composta por várias unidades de processamento, cujo funcionamento é bastante simples. Essas unidades são geralmente conectadas por canais de comunicação que estão associados a determinado peso. As unidades fazem operações apenas sobre seus dados locais, que são entradas recebidas pelas suas conexões.

A operação de uma unidade de processamento, proposta por MCCULLOCH E PITTS [66], pode ser resumida da seguinte maneira:

- sinais são apresentados à entrada;
- cada sinal é multiplicado por um número, ou peso, que indica a sua influência na saída da unidade;
- é feita a soma ponderada dos sinais que produz um grau de atividade;
- se esse grau de atividade exceder um dado limite (*threshold*), a unidade produz uma determinada resposta de saída.

Neste sentido, considere p sinais de entrada X_1, X_2, \dots, X_p , pesos w_1, w_2, \dots, w_p e limiar t . Os sinais assumem valores booleanos (0 ou 1) e pesos assumem valores reais. Nesse modelo, o grau de atividade a é dado por:

$$a = w_1X_1 + w_2X_2 + \dots + w_pX_p \quad (2.21)$$

A saída y é dada por

$$y = 1, \text{ se } a \geq t \quad (2.22)$$

ou

$$y = 0, \text{ se } a < t \quad (2.23)$$

A maioria dos modelos de redes neurais possui alguma regra de treinamento, onde os pesos de suas conexões são ajustados de acordo com os padrões apresentados. Em outras palavras, as redes aprendem por meio de exemplos. Arquiteturas neurais são tipicamente organizadas em camadas, com unidades que podem estar conectadas às unidades da camada posterior.

Normalmente as camadas são classificadas em três grupos:

1. camada de entrada, onde os padrões são apresentados à rede;
2. camadas intermediárias ou ocultas, onde é feita a maior parte do processamento, por meio das conexões ponderadas; podem ser consideradas como extratoras de características;
3. camada de saída, onde o resultado final é concluído e apresentado.

Vale ressaltar que uma rede neural é especificada pela sua topologia, pelas características dos nós e pelas regras de treinamento.

Nas próximas seções serão apresentados os processos de aprendizado das redes neurais.

2.7.3 PROCESSOS DE APRENDIZAGEM

A propriedade mais importante das redes neurais é a habilidade de aprender a partir de seu ambiente e com isso melhorar seu desempenho. Isso é feito por um processo iterativo de ajustes aplicado a seus pesos, denominado treinamento. O aprendizado se concretiza quando a rede neural atinge uma solução generalizada para uma classe de problemas. Denomina-se algoritmo de aprendizado um conjunto de regras bem definidas para a solução de um problema de aprendizado. Existem muitos tipos de algoritmos de aprendizado específicos para determinados modelos de redes neurais. Esses algoritmos diferem entre si principalmente pelo modo como os pesos são modificados.

Outro fator importante é a maneira pela qual uma rede neural se relaciona com o ambiente. Nesse contexto existem os seguintes paradigmas de aprendizado:

- aprendizado supervisionado, quando é utilizado um agente externo que indica à rede, a resposta desejada para o padrão de entrada;
- aprendizado não supervisionado (auto-organização), quando não existe um agente externo indicando a resposta desejada para os padrões de entrada;
- reforço, quando a resposta fornecida pela rede é avaliada externamente.

Denomina-se ciclo uma apresentação de todos os N pares (entrada e saída) do conjunto de treinamento no processo de aprendizado. A correção dos pesos num ciclo pode ser executada de dois modos:

1. Modo Padrão: a correção dos pesos acontece a cada apresentação, à rede, de um exemplo do conjunto de treinamento. Cada correção de pesos baseia-se somente no erro do exemplo apresentado naquela iteração. Assim, em cada ciclo ocorrem N correções.
2. Modo *Batch*: apenas uma correção é feita por ciclo. Todos os exemplos do conjunto de treinamento são apresentados à rede. Seu erro médio quadrático é calculado. A partir desse erro fazem-se as correções dos pesos.

2.7.4 TREINAMENTO SUPERVISIONADO

O treinamento supervisionado da rede neural *Perceptron* consiste em ajustar os pesos e os limiares de suas unidades para que a classificação desejada seja obtida. Pode-se considerar o limiar como sendo o peso associado a uma conexão, cuja entrada é sempre igual a -1 e adaptar o peso relativo a essa entrada.

Quando um padrão é inicialmente apresentado à rede, ela produz uma saída. Após medir a distância entre a resposta atual e a desejada, são realizados os ajustes apropriados nos pesos das conexões de modo a reduzir essa distância.

Deste modo o esquema de treinamento é apresentado no pseudocódigo descrito pelo algoritmo a seguir.

Algoritmo 2 - Algoritmo para treinamento supervisionado.

Iniciar todas as conexões com pesos aleatórios;

Repetir até que o erro E seja satisfatoriamente pequeno ($E \leq e$)

For cada par de treinamento (X,d) **Do**

Calcular a resposta obtida O ;

If erro não for satisfatoriamente pequeno ($E > e$) **then**

Atualizar pesos: $W_{novo} = W_{anterior} + E$

No pseudocódigo apresentado, o par de treinamentos (X,d) corresponde ao padrão de entrada e a sua respectiva resposta desejada. O erro E é definido como resposta desejada menos a resposta obtida ($R_{desejada} - R_{Obtida}$). A taxa de aprendizado é uma constante positiva, que corresponde à velocidade do aprendizado.

2.7.5 O ALGORITMO *BACKPROPAGATION*

O algoritmo *Backpropagation* é o algoritmo para treinamento de redes neurais multicamadas mais utilizado. Baseia-se no aprendizado supervisionado por correção de erros. Ele é constituído por:

1. propagação. depois de apresentado o padrão de entrada, a resposta de uma unidade é propagada como entrada para as unidades na camada seguinte,

até a camada de saída, onde é obtida a resposta da rede e o erro é calculado. Esse processo está ilustrado na Figura 26.




FIGURA 26 - FASE DE PROPAGAÇÃO. FONTE: LNCC [71].

2. retropropagação (*backpropagation*). Desde a camada de saída até a camada de entrada, são feitas alterações nos valores das conexões (pesos sinápticos). Esse processo é ilustrado na Figura 27.




FIGURA 27 - FASE DE RETROPROPAGAÇÃO. FONTE: LNCC [71].

Durante a fase de treinamento deve-se apresentar um conjunto formado pelo par “entrada para a rede” e “valor desejado para resposta à entrada”. A saída será comparada ao valor desejado e o erro global da rede será calculado. O erro influenciará na correção dos pesos sinápticos no passo de retropropagação. Apesar de não haver garantias que a rede forneça uma solução ótima para o problema, esse processo é muito utilizado por apresentar uma boa solução para o treinamento de *perceptrons* multicamadas.

Resumidamente, o algoritmo funciona da seguinte forma:

1. inicialização. Inicializar os pesos sinápticos e os *bias* (níveis de corte) aleatoriamente, com valores no intervalo $[-1; 1]$;

2. apresentação dos exemplos de treinamento. (i) Treinamento *online*, ou seja, para cada exemplo do conjunto de treinamento, efetuar os passos 3 e 4 e; (ii) treinamento em lote, ou seja, para cada época do conjunto de treinamento, efetuar os passos 3 e 4;
3. computação para frente (*propagação*). Depois de apresentado o exemplo do conjunto de treinamento $T = (x(n), d(n))$, sendo $x(n)$ a entrada apresentada à rede e $d(n)$ a saída desejada, calcular o valor da ativação v_j e a saída para cada unidade da rede, da seguinte forma:

$$v_j = \sum_{i=1}^m w_{ij}x_i + b \quad (2.24)$$

onde os w_{ij} são os pesos e b é o *bias*. Para o cálculo do valor de ativação e

$$y = f(v) = \frac{1}{1+e^{-av}} \quad (2.25)$$

para o cálculo da saída y da unidade k , utilizando a função sigmóide, ou uma outra função se necessário.

Utilizar a saída das unidades de uma camada como entrada para a seguinte, até a última camada. A saída das unidades da última camada será a resposta da rede.

4. calcular o sinal de erro. Fazendo a saída $y_j = O_{j(n)}$, será $O_{j(n)}$ a resposta da rede, calcule o sinal de erro $e_{j(n)}$ pela seguinte fórmula:

$$e_{j(n)} = d_{j(n)} - O_{j(n)} \quad (2.26)$$

onde $d_{j(n)}$ é a saída desejada como resposta para cada unidade na interação (n) . Este sinal de erro será utilizado para computar os valores dos erros das camadas anteriores e fazer as correções necessárias nos pesos sinápticos.

5. retropropagação. Calcular os erros locais, δ_{jn} , para cada unidade, desde a camada de saída até a de entrada. O gradiente local é definido por:

$$\delta_{j(n)} = e_{j(n)} O_{j(n)} (1 - O_{j(n)}) \quad (2.27)$$

para a unidade da camada de saída e,

$$\delta_{j(n)} = O_{j(n)} O_{j(n)} (1 - O_{j(n)}) \sum \delta_k w_{jk} \quad (2.28)$$

para as unidades das demais camadas, onde $O_j(1 - O_{j(n)})$ é a função de ativação diferenciada em função do argumento, isto é, valor de ativação; k é o erro das unidades da camada anterior conectadas à unidade j e; w_{jk} são os pesos das conexões com a camada anterior. Após o cálculo dos erros de

cada unidade, calcular o ajuste dos pesos de cada conexão segundo a regra delta generalizada. Atualizar os pesos para o cálculo dos ajustes dado por:

$$\Delta w_{kj}(n+1) = \alpha w_{kj}(n) + \eta \delta_j y_j \quad (2.29)$$

fazer $w(n+1) = w(n) + \Delta w_{kj}(n)$, para atualizar os pesos sinápticos. Na equação 2.29 α é a constante de momentum (quando $\alpha = 0$ esta função funciona como a regra delta comum), η é a taxa de aprendizado; δ_j é o erro da unidade, y_j é a saída produzida pela unidade j .

6. iteração. Repetir os itens 3, 4 e 5 referentes à propagação, cálculo do erro e retropropagação, apresentando outros estímulos de entrada, até que sejam satisfeitas as condições de treinamento. As condições de treinamento podem ser: (i) o erro da rede está baixo, sendo pouco alterado durante o treinamento e; (ii) o número máximo de ciclos de treinamento foi alcançado.

2.7.6 MAPAS AUTO-ORGANIZÁVEIS DE KOHONEN

A rede SOM (*Self-Organizing Map*) é um tipo de rede neural artificial que é treinada utilizando-se aprendizagem não supervisionada para produzir uma distribuição bidimensional (mapa), que é a representação discretizada do espaço de entrada das amostras de treinamento. Elas possuem a propriedade de efetivamente criar de forma espacialmente organizada, uma “representação interna” de várias características de sinais de entrada e suas abstrações [72,73].

As redes neurais SOM operam em dois modos: treinamento e mapeamento. O treinamento constrói o mapa utilizando os exemplos fornecidos na entrada da rede. O mapeamento classifica automaticamente um novo vetor de entrada.

A rede SOM é uma técnica de visualização de dados inventados por KOHONEN [72,73] que reduz as dimensões dos dados por meio do uso de auto-organização de redes neurais. O problema que a visualização de dados tenta resolver está associado ao fato de que os humanos simplesmente não podem visualizar dados de alta dimensão. As SOMs são criadas para ajudar a entender esses tipos de dados. A SOM faz a redução das dimensões por meio de um mapa com, uma ou duas dimensões geralmente, que associa as semelhanças entre os dados, agrupando itens do espaço de entrada semelhantes em conjunto.

A primeira parte de uma rede SOM são os dados. A ideia dos mapas auto-organizáveis é que eles consigam projetar os dados com N -dimensões em algo que seja melhor compreendido visualmente (um mapa de imagem de duas dimensões).

A segunda parte são os vetores peso. Cada vetor peso tem dois componentes: (i) dado, tem mesma dimensão dos vetores do espaço de entrada (amostra) e ; (ii) localização do vetor no mapa.

A SOM assume uma estrutura topológica dentre unidades de *clusters*. Esta propriedade é observada no cérebro, no entanto, não é observada em outras redes neurais artificiais. Existem m unidades de clusters, que podem ser arranjados em uma ou duas matrizes dimensionais [74].

O vetor peso w da rede neural SOM para uma unidade de cluster serve como um exemplar do padrão de entrada associado com o *cluster*. Durante o processo de auto-organização, a unidade *cluster* cujos pesos que mais se aproximam da entrada padrão (tipicamente, o quadrado da menor distância euclidiana) são escolhidos como vencedores. Os pesos dos vetores das unidades vizinhas não estão, em geral, pertos do padrão de entrada. Por exemplo, para um cluster num vetor linear de unidades de clusters, o vizinho de raio R ao longo do *cluster* J , consiste de todas as unidades j tais que $\max(1, J-R) \leq j \leq \min(J+R, m)$ [74].

A arquitetura para o vetor de entrada \mathbf{x} , dados de saída \mathbf{y} e pesos da rede SOM é mostrada na Figura 28. Vizinhos da unidade designada por # de raios $R=2, 1$ e 0 , em uma topologia unidimensional (com 10 unidades de *clusters*), é mostrada na Figura 29. Os vizinhos de raios $R=2, 1$ e 0 são mostrados nas Figuras 30 e 31 para representação bidimensional em um mapa retangular e hexagonal, respectivamente, com 49 unidades cada. Em cada ilustração a unidade vencedora é indicada pelo símbolo “#” e outras unidades por “*”. Cada unidade tem oito vizinhos no mapa retangular e seis no mapa hexagonal.

Unidades vencedoras que estiverem próximas à borda do mapa terão menos vizinhos que os mostrados para o vencedor nas figuras [74].




FIGURA 28 - ARQUITETURA REDE SOM. FONTE: FAUSETT [74].

* * * { * (* [#] *) * } * *

FIGURA 29 - MODELO PARA UM VETOR LINEAR DE UNIDADES DE CLUSTERS E SUA RELAÇÃO COM O RAIOS R: PARA { }, R=2, (), R=1 E [], R=0. FONTE: FAUSETT [74].




FIGURA 30 - REPRESENTAÇÃO VIZINHOS “*” A UMA UNIDADE CLUSTER “#” REDE SOM PARA MAPA RETANGULAR. FONTE: FAUSETT [74].




FIGURA 31 - REPRESENTAÇÃO VIZINHOS “*” A UMA UNIDADE CLUSTER “#” REDE SOM PARA MAPA HEXAGONAL. FONTE: FAUSETT [74].

O algoritmo da rede SOM de KOHONEN é apresentado a seguir:

- Passo 0: inicialize os pesos w_{ij} . Os pesos iniciais podem assumir valores aleatórios. Defina os parâmetros da topologia dos vizinhos. Defina os parâmetros para taxa de aprendizagem α .
- Passo 1: enquanto a condição de parada é falsa, faça Passos 2 - 8.
 - Passo 2: para cada vetor de entrada x , faça passos 3 – 5.

- Passo 3: para cada j , calcule:

$$D(j) = \sum_i (w_{ij} - x_i)^2 \quad (2.30)$$

- Passo 4: encontre os índices J tais que $D(j)$ é mínimo.
- Passo 5: para todas as unidades j dentro de um vizinho específico de J , e para todo i :

$$w_{ij}(\text{novo}) = w_{ij}(\text{velho}) + \alpha[x_i - w_{ij}(\text{velho})] \quad (2.31)$$

- Passo 6: atualize a taxa de aprendizagem α .
- Passo 7: reduza raio da topologia dos vizinhos a tempos específicos.
- Passo 8: teste a condição de parada.

A seguir apresenta-se um exemplo da rede SOM. Considere-se quatro vetores para serem agrupados: (1,1,0,0); (0,0,0,1); (1,0,0,0) e (0,0,1,1). O máximo número de clusters para serem formados é dois ($m-2$) e suponha taxa de aprendizagem (decréscimo geométrico) igual a $\alpha(0)=0,6$ e $\alpha(t+1)=0,5\alpha(t)$. Assim,

- Passo 0: inicializa os pesos, raio inicial $R=0$, e taxa inicial $\alpha(0)=0,6$.

$$\begin{bmatrix} 0,2 & 0,8 \\ 0,6 & 0,4 \\ 0,5 & 0,7 \\ 0,9 & 0,3 \end{bmatrix}$$

- Passo 1: Inicia treinameto.
 - Passo 2. Para o primeiro vetor de entrada (1,1,0,0), faça passos 3 – 5.

- Passo 3: para cada j , calcule:

$$\begin{aligned} D(1) &= (0,2 - 1)^2 + (0,6 - 1)^2 + (0,5 - 0)^2 + (0,9 - 0)^2 \\ &= 1,86; \end{aligned}$$

$$\begin{aligned} D(2) &= (0,8 - 1)^2 + (0,4 - 1)^2 + (0,7 - 0)^2 + (0,3 - 0)^2 \\ &= 0,98; \end{aligned}$$

- Passo 4: o vetor de entrada está perto do nodo 2, assim, $J=2$
 - Passo 5: os pesos sobre a unidade vencedora são atualizados

$$\begin{aligned} w_{i2}(\text{novo}) &= w_{i2}(\text{velho}) + 0,6[x_i - w_{i2}(\text{velho})] \\ &= 0,4w_{i2}(\text{velho}) + 0,6x_i \end{aligned}$$

Isso dá a nova matriz de pesos

$$\begin{bmatrix} 0,2 & 0,92 \\ 0,6 & 0,76 \\ 0,5 & 0,28 \\ 0,9 & 0,12 \end{bmatrix}$$

- Passo 2: para o segundo vetor de entrada (0,0,0,1), faça passos 3 – 5.
 - Passo 3: para cada j , calcule:

$$D(1) = (0,2 - 0)^2 + (0,6 - 0)^2 + (0,5 - 0)^2 + (0,9 - 1)^2 \\ = 0,66;$$

$$D(2) \\ = (0,92 - 0)^2 + (0,76 - 0)^2 + (0,28 - 0)^2 \\ + (0,12 - 1)^2 = 2,2768;$$

- Passo 4: o vetor de entrada está perto do nodo 1, assim, $J=1$
- Passo 5: atualiza a nova matriz de pesos

$$\begin{bmatrix} 0,08 & 0,92 \\ 0,24 & 0,76 \\ 0,20 & 0,28 \\ 0,96 & 0,12 \end{bmatrix}$$

- Passo 2: para o terceiro vetor de entrada (1,0,0,0), faça passos 3 – 5. Obtém-se.

$$\begin{bmatrix} 0,08 & 0,968 \\ 0,24 & 0,304 \\ 0,20 & 0,112 \\ 0,96 & 0,048 \end{bmatrix}$$

- Passo 2: para o quarto vetor de entrada (0,0,1,1), faça passos 3 – 5. Obtém-se.

$$\begin{bmatrix} 0,032 & 0,968 \\ 0,096 & 0,304 \\ 0,680 & 0,112 \\ 0,984 & 0,048 \end{bmatrix}$$

- Passo 6: atualize a taxa de aprendizagem $\alpha = 0,5(0,6) = 0,3$.

A matriz de pesos após a segunda época de treinamento será

$$\begin{bmatrix} 0,16 & 0,980 \\ 0,047 & 0,360 \\ 0,630 & 0,055 \\ 0,999 & 0,024 \end{bmatrix}$$

Após 100 iterações, os pesos da matriz convergem para a matriz

$$\begin{bmatrix} 0,0 & 1,0 \\ 0,0 & 0,5 \\ 0,5 & 0,0 \\ 1,0 & 0,0 \end{bmatrix},$$

onde a primeira coluna é a média dos dois vetores colocados no cluster 1, a segunda é a média de dois vetores colocados no cluster 2.

Geralmente, representa-se a rede SOM num mapa RGB, onde a cor é o dado e a localização do vetor é sua posição (x,y) de um *pixel* na tela. A Figura 32 mostra o modelo de trabalho da rede SOM no MATLAB [75].




FIGURA 32 - MODELO REDE SOM: ENTRADA, CAMADA (W É O FATOR DE PESO DA REDE) E SAÍDA. FONTE: MANUAL MATLAB [75].

Na Figura 33 está mostrada a representação da topologia da rede SOM na *Toolbox* de Redes Neurais do MATLAB [75]. Nesse caso há 64 neurônios posicionados em uma malha hexagonal de dimensão 8 x 8. Cada neurônio aprende a representar uma diferente classe do objeto a ser estudado. Neurônios adjacentes indicam classes similares. Cores escuras representam pesos altos. Se duas entradas têm peso similar (mesma cor) isso indica que elas são altamente correlacionadas.




FIGURA 33 - TOPOLOGIA REDE SOM COM 64 NODOS. FONTE: MANUAL MATLAB [75].

Redes SOM são aplicáveis para criar classificações. Elas fornecem a informação da topologia das classes, o que permite verificar quais são mais similares. Um exemplo dado por KOHONEN [73] foi o da taxonomia (agrupamento hierárquico) de um vetor composto de dados abstratos e características hipotéticas. Na Tabela 1 estão mostrados 32 itens, cada um com cinco características hipotéticas, a_1 até a_5 . Cada uma das colunas representa um item nomeado de A até 6. Os valores das características (a_1, a_2, \dots, a_5) constituem o vetor padrão de dados de entrada x . A Figura 34 mostra o mapa de pesos dos dados obtido no MATLAB. Pode-se verificar na figura como se dá os agrupamentos (pelas cores) comparando com os dados da Tabela 1 com o mapa.

TABELA 1 - DADOS HIPOTÉTICOS QUE COMPÕE O VETOR DE ENTRADA DO EXEMPLO APRESENTADO EM 1990 POR KOHONEN [73].

Item																																
Id	A	B	C	D	E	F	G	H	I	J	K	L	M	N	O	P	Q	R	S	T	U	V	W	X	Y	Z	1	2	3	4	5	6
a_1	1	2	3	4	5	3	3	3	3	3	3	3	3	3	3	3	3	3	3	3	3	3	3	3	3	3	3	3	3	3	3	3
a_2	0	0	0	0	0	1	2	3	4	5	3	3	3	3	3	3	3	3	3	3	3	3	3	3	3	3	3	3	3	3	3	3
a_3	0	0	0	0	0	0	0	0	0	0	1	2	3	4	5	6	7	8	3	3	3	3	6	6	6	6	6	6	6	6	6	6
a_4	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	1	2	3	4	1	2	3	4	2	2	2	2	2	2
a_5	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	1	2	3	4	5	6

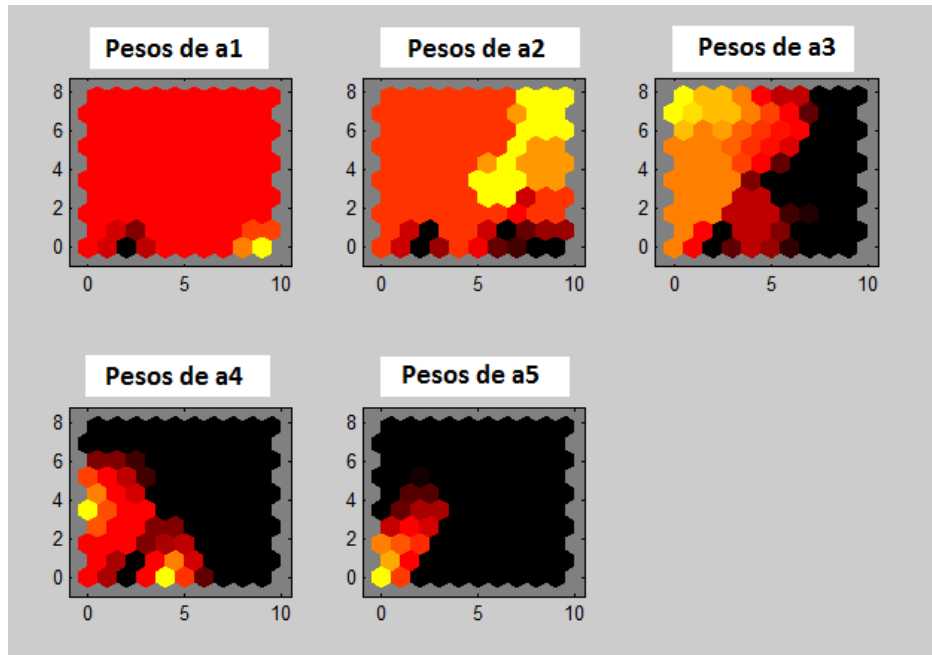


FIGURA 34 - PESOS OBTIDOS DA REDE SOM PARA OS DADOS DA TABELA 1. FONTE: O AUTOR.

A Figura 35 mostra o plano de pesos para cada uma das 4 características dos três tipos de flores dos dados de FISHER [64]. Os quatro atributos das flores irão agir como entradas na SOM, que serão mapeadas em camadas de neurônios em duas dimensões. Esse é um exemplo de um problema de agrupamento, onde se pode criar grupos de amostras baseadas nas similaridades entre as amostras. Na Figura 35 são visualizados os pesos que conectam cada entrada a cada um dos 64 neurônios numa malha hexagonal de 8 x 8 neurônios. A Figura 35 permite ver uma boa separação de classes nos planos de F3 e F4 (características das flores).

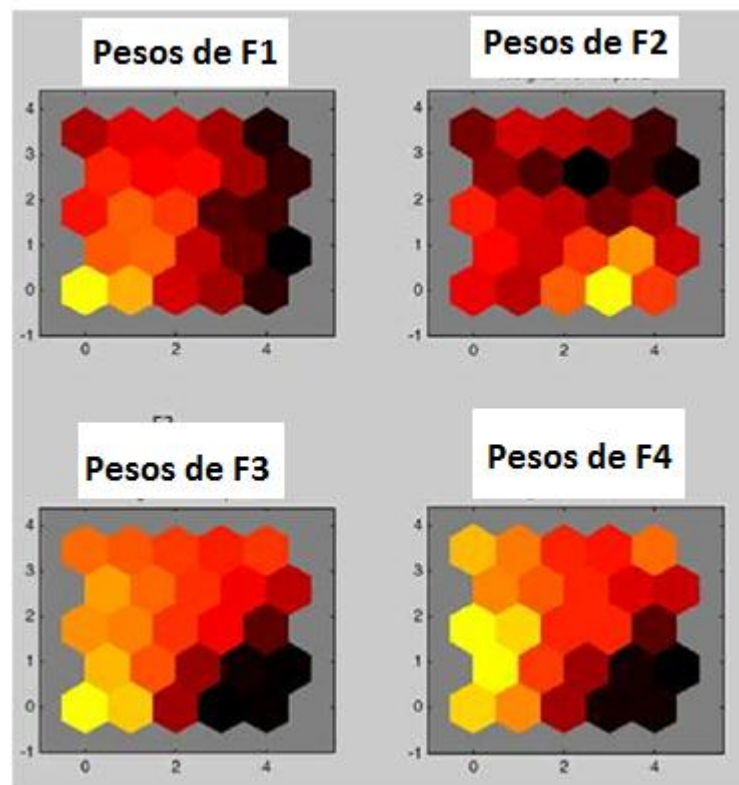


FIGURA 35 - PESOS DOS NEURÔNIOS PARA A REDE SOM DOS DADOS DE FISHER [64]. PLANO DE PESOS PARA CADA UMA DAS QUATRO CARACTERÍSTICAS DAS FLORES (F1 ATÉ F4). CORES ESCURAS REPRESENTAM TODOS PESOS ALTOS PARA OS DADOS DE ENTRADA. F3 E F4 MOSTRAM MELHOR A SEPARAÇÃO DAS TRÊS CLASSES. FONTE: MANUAL MATLAB [75].

2.8 CONFIABILIDADE EM END

Na área médica, existem diversos tipos de técnicas de diagnóstico de imagens usadas para identificação de patologias em pacientes. Entretanto a precisão desses exames é alvo constante de questionamento. Quais são os “prejuízos” de um erro de laudo médico se o paciente tem um grave problema de saúde e ele não consegue detectá-lo pelo método de diagnóstico escolhido? E se o paciente não tem nenhum problema e o laudo médico aponta o contrário? Que consequências há num erro de laudo médico? Se na área médica os riscos assumidos em laudos imprecisos podem levar a graves consequências, o que pode acontecer com o resultado de uma inspeção de equipamento, por exemplo, sem confiabilidade? Ao contrário da área médica, ao invés de um caso fatal, poderá haver sérias consequências, danos ambientais, perdas financeiras irreparáveis, etc.

A confiabilidade da aplicação de um método de inspeção não destrutivo de materiais está relacionada a vários fatores, e o correto entendimento da influência de cada um é um assunto complexo, muitas vezes difícil de quantificar, e objeto de

muitos estudos ao longo das últimas décadas. Alguns desses estudos serão abordados neste trabalho.

2.8.1 CURVAS POD (PROBABILIDADE DE DETECÇÃO)

A forma mais utilizada de avaliação da confiabilidade de um método não destrutivo é por meio das curvas PoD (*Probability of Detection* - Probabilidade de Detecção) que medem a probabilidade de detecção de um defeito de uma determinada dimensão. A curva PoD estima a capacidade de detecção de um método de inspeção em função da dimensão de uma descontinuidade. Considerando um método ideal, a PoD para descontinuidades menores do que um dado tamanho crítico é zero. Para descontinuidades maiores do que esse valor, a PoD é 1 (100% de probabilidade de detecção). Num caso ideal, não haveria o que se conhece por Falso Positivo (reprovação de componentes perfeitos) ou Falso Negativo (aprovação de componentes com problemas em sua integridade). Todavia, a realidade aponta para curvas que não têm comportamento de idealidade, havendo regiões de Falsos Positivos e Falsos Negativos. Na Figura 36 É mostrada uma PoD real e uma PoD ideal [76].




FIGURA 36 - MODELO DE CURVAS POD REAL E IDEAL. FONTE: CARVALHO [76].

A maneira mais usual de construção dessas curvas é por teste empírico. O mais conhecido é o método de *Round Robin Testing* (RRT). Nesse método, uma série de inspetores são submetidos a corpos-de-prova com defeitos introduzidos artificialmente, simulando defeitos reais que possam ser encontrados, por exemplo,

em juntas soldadas. Os defeitos fabricados têm normalmente dimensões variadas com aumento de comprimento. As curvas podem ser traçadas usando-se somente os resultados de um inspetor, ou também com base no resultado de um grupo de inspetores [77]. Destacam-se dois pontos principais nessa metodologia: o primeiro é que é necessária uma quantidade suficiente de corpos de prova para garantir confiabilidade estatística na estimativa da curva; o segundo é que a confecção de corpos de provas com defeitos de dimensões, localizações e características reais normalmente é extremamente difícil.

2.8.2 CURVAS ROC (*RECEIVER OPERATING CHARACTERISTIC*)

As curvas ROC (*Receiver ou Relative Operating Characteristic*) são abordadas em referências de técnicas de reconhecimento de padrões [78,79]. Essas curvas são resultantes da relação entre o número de falsos positivos (FP), eixo das abscissas, e o número de verdadeiros positivos (VP), eixo das ordenadas. Assim como em PoD, a confiabilidade é medida pela área sob a curva. Quanto maiores os valores de VP, e menores os valores de FP, maior será a confiabilidade da técnica. A confiabilidade ideal é de uma área de 100% referente a um quadrado, conforme exemplo didático da Figura 37.




FIGURA 37 - MODELO DE CURVA ROC. FONTE: SILVA [78].

A probabilidade de detecção (PoD), ou em outras palavras, a Probabilidade de Verdadeiro-Positivo (*PVP*) será:

$$PVP = \frac{VP}{VP+FN} \quad (2.32)$$

onde FN é o valor de Falso Negativo.

A probabilidade de Falso Alarme, ou Probabilidade de Falso Positivo (PFP)

$$PFP = \frac{FP}{FP+VN} \quad (2.33)$$

onde VN é o valor de Verdadeiro Negativo.

As curvas ROC apresentam algumas vantagens em relação às curvas PoD, como a possibilidade de avaliação dos índices de falsos positivos, que não são levados em conta na construção das curvas de probabilidade de detecção. Sem dúvida que esses índices são muito importantes quando se trata de END, onde situações em que uma provável indicação falsa de defeito pode acarretar em prejuízos financeiros elevados para as empresas envolvidas, gerando paradas de funcionamento desnecessárias de algum equipamento.

2.8.3 ESTIMANDO A ACURÁCIA DOS CLASSIFICADORES

Um dos problemas a resolver por um sistema de detecção automática de defeitos é a separação de defeitos reais no isolador (Verdadeiros - Positivos) e defeitos criados por artefatos do detector (Falsos - Positivos). A Figura 38 ilustra isso.




FIGURA 38 - RADIOGRAFIA DIGITAL DE UM ISOLADOR TIPO ROLDANA, ONDE OS FALSOS-POSITIVOS, NESTE CASO, *PIXELS* DEFEITUOSOS DO DETECTOR DIGITAL (ARTEFATO TIPO ESTRELAS INDICADO PELOS CÍRCULOS) E UMA BOLHA REAL (VERDADEIRO-POSITIVO, DENTRO DO QUADRADO PRETO) PODEM SER VISTOS. FONTE: O AUTOR.

Existem diversas técnicas para estimar a acurácia de um classificador, os quais são definidos como o grau de acerto de classificação dos dados. As três técnicas mais utilizadas são: seleção aleatória simples dos dados, validação cruzada com diversas implementações [80], e o *bootstrap* [81]. Não há como confirmar qual das técnicas é a melhor para um sistema de classificação de padrões específico. A escolha de qual técnica será utilizada dependerá da quantidade de dados avaliados e da classificação específica a ser realizada.

Como descrito por Efron [81], duas propriedades são importantes quando se calcula a eficiência do estimador, seu *bias* e sua variância definidas nas equações 2.33 e 2.35, respectivamente:

$$Bias = E[\theta] - \theta \quad (2.34)$$

$$Var(\theta) = E[(\theta - E[\theta])^2] \quad (2.35)$$

onde $E[\theta]$ é a esperança matemática do estimador θ e $Var(\theta)$ é a variância do estimador.

Um estimador é dito confiável se contém baixos valores de bias e variância. Entretanto, na prática, uma relação apropriada entre ambos é desejável quando se quer resultados mais realistas [80,81]. Para um classificador, bias e variância da acurácia estimada variam em função do número de dados e da técnica utilizada para estimar a acurácia usada.

Neste trabalho, para calcular a acurácia de classificação de defeitos em isoladores, duas técnicas de seleção aleatória de dados foram aplicadas:

1. seleção aleatória sem reposição de 80% do grupo total de dados (50 amostras) para a construção do grupo de treinamento. Os dados não escolhidos para treinamento foram utilizados para teste (40 treinamento e 10 amostras para teste). Um total de cinco pares de treinamento e testes foram feitos.
2. seleção aleatória com reposição usando a técnica de *bootstrap*. Um grupo de dados de *bootstrap* (tamanho n), de acordo com a definição de Efron [81], foi construído para os dados x_1, x_2, \dots, x_n obtidos de forma aleatória e com reposição, de um grupo original de dados $x_1^*, x_2^*, \dots, x_n^*$ (também de tamanho n). Dessa maneira, foi possível que alguns dados aparecessem 1, 2, 3 ou n

vezes ou nunca. Com essa técnica, o classificador, utilizando o i -ésimo grupo de treinamento, foi testado com os dados que não foram utilizados nesse grupo, resultando numa acurácia do estimador de θ_i (para os dados de teste). Isso foi repetido b vezes. O modelo para estimar acurácia de classificadores por *bootstrap*, frequentemente usado, é definido de acordo com a Equação 4.5.

$$\theta_B = \frac{1}{b} \sum \omega \theta_i + (1 - \omega) \theta_c \quad (4.5)$$

onde θ_c é a acurácia aparente (calculada com os dados de teste apenas) [78] e o peso ω varia entre 0,632 e 1. O peso ω é normalmente adotado como sendo igual a 0,6321920.

2.9 DEFEITOS EM ISOLADORES POLIMÉRICOS

Esta tese utiliza como estudo de caso o problema de defeitos internos em isoladores poliméricos. Assim, faz-se aqui uma pequena abordagem desse problema e a produção do componente.

Na manufatura de um isolador polimérico, o caráter reológico tem fundamental importância. O conhecimento do comportamento dos polímeros sob fluxo é determinante para a seleção destes para produção do isolador ou outras aplicações ou processos. Os polímeros apresentam comportamento viscoelástico ao se deformarem. Viscoelasticidade é um comportamento ou resposta à deformação, podendo ser viscoso (o corpo se deforma e não recupera a forma original, mesmo quando, retirada a tensão aplicada, conhecida como deformação plástica) e elástico (recuperação total da deformação após retirada da tensão aplicada sobre o corpo) [82].

Existem diversas técnicas envolvendo o processo de injeção, como por exemplo, a injeção por água e a microinjeção. Para a produção do isolador polimérico utiliza-se a técnica convencional. De forma bem resumida, pode-se dizer que a injetora é capaz de homogeneizar e injetar o polímero fundido em um molde capaz de dar a forma à massa polimérica. Está é injetada no interior do molde sob alta pressão e com velocidade controlada [82].

Um dos problemas apontados na injeção, e que pode ocasionar defeitos nos isoladores, é o gradiente de temperatura. Quando o polímero é injetado no molde a massa pode ter variação de temperatura. Consequentemente, o gradiente de temperatura pode ocasionar a formação de camadas dentro do molde com diferentes temperaturas: a variação na taxa de resfriamento, a variação da taxa de enchimento das diferentes partes do molde e diferentes propriedades físicas ao longo da peça manufaturada [82]. Na Figura 39 está ilustrada a formação de uma bolha em um isolador em função das variações de temperatura entre a superfície externa e seu interior (gradiente) em situação de resfriamento.




FIGURA 39 - MODELO PARA GRADIENTE DE TEMPERATURA EM UM ISOLADOR TIPO PINO EM PROCESSO DE RESFRIAMENTO E O SURGIMENTO DE UMA BOLHA DE AR. AS REGIÕES INTERNAS T2 RESFRIAM MAIS LENTAMENTE QUE AS REGIÕES PRÓXIMAS À SUPERFÍCIE T1. FONTE: O AUTOR.

Existem diversas normas para procedimentos de ensaios em isoladores, no entanto, cabe à concessionária de energia elétrica definir quais os ensaios solicitar ao distribuidor no intuito de garantir o funcionamento adequado do componente em serviço. Por exemplo, a CELG (Companhia Energética de Goiás) em sua norma NDT-25, determina as condições mínimas exigíveis para a fabricação e o recebimento de isoladores compostos poliméricos do tipo bastão para ancoragem de linhas e redes aéreas convencionais e compactas, com tensões nominais de 13,8 e 34,5 kV [83].

As técnicas de radiografia e tomografia industrial, apesar dos resultados que podem propiciar na detecção de defeitos de componentes elétricos, ainda não são solicitadas pelas maiorias das concessionárias, no entanto, normas estão sendo

elaboradas para colocar esse tipo de ensaio como parte do processo de controle de qualidade dos componentes.

2.3 FERRAMENTAS DE DESENVOLVIMENTO COMPUTACIONAL PARA APLICAÇÕES EM TOMOGRAFIA INDUSTRIAL 3D

O VTK (*Visualization Toolkit*) é uma ferramenta de visualização distribuída sob o critério código aberto. O termo código aberto, ou *Open Source* em inglês, refere-se a *software* também conhecido por *software* livre. O VTK é disponível para computação gráfica 3D, processamento de imagens e visualização científica. Consiste de uma biblioteca C++ e várias camadas interpretáveis incluindo Tcl/Tk, Java, Python e C# para ambiente .NET. A empresa *Kitware* está envolvida com o desenvolvimento e suporte dessa biblioteca. O VTK suporta uma larga variedade de algoritmos de visualização incluindo: escalar, vetorial, uso de tensor, texturas e métodos volumétricos; e técnicas de modelagem avançada tais como: modelagem implícita, redução poligonal, suavização, e triangulação de Delaunay. Tais algoritmos são bastante úteis para desenvolvimento de *software* em tomografia industrial 3D. O VTK é multiplataforma, podendo ser utilizado em Linux, Windows, Mac OS e Unix [84].

A interface para desenvolvimento denominada NetBeans foi iniciada em 1996 por dois estudantes tchecos na Universidade de Charles, em Praga. Em 1999 o projeto já havia evoluído para uma IDE (*Integrated Development Environment*) proprietária, com o nome de NetBeans Developer X2, nome que veio da ideia de reutilização de componentes que foram a base do Java. Nessa época a empresa Sun Microsystems havia desistido de sua IDE Java Workshop e, procurando por novas iniciativas, adquiriu o projeto NetBeans DeveloperX2 incorporando-o a sua linha de software. A Sun Microsystems fundou o projeto *Open Source* NetBeans em junho de 2000. Atualmente, a Oracle possui direitos do produto que continuou com a filosofia da Sun em termos de distribuir gratuitamente o produto. A IDE NetBeans auxilia programadores a escrever, compilar, depurar e instalar aplicações, e foi arquitetada em forma de uma estrutura reutilizável que visa a simplificar o desenvolvimento e aumentar a produtividade, pois reúne em uma única aplicação todas essas funcionalidades. O Netbeans é totalmente escrito em Java, mas pode

suportar qualquer outra linguagem de programação, como C, C++, Ruby e PHP, XML e HTML.

Para utilizar o VTK no código Java, após instalar o VTK, basta o programador importar o `vtk.jar` ao código na IDE Netbeans. A vantagem de se utilizar o `vtk.jar` é a incorporação direta do `vtkPanel`, que é o painel para visualização das imagens tridimensionais renderizadas, no ambiente de desenvolvimento visual da interface desenvolvida para o usuário, além do que, o `vtk.jar` permite acesso direto às classes do VTK.

A classe `vtkMassProperties` provê meios para o cálculo da superfície, volume e fator de forma de um objeto 3D. Como classe processa somente triângulos, utiliza-se adicionalmente a ela a classe `vtkTriangleFilter` para converter as iso-superfícies em polígonos triangulares. A classe `vtkMassProperties` foi desenvolvida baseada no trabalho intitulado “*Evaluation of New Algorithms for the Interactive Measurements of Surface Area and Volume*” de ALYASSIN *et al.* [85].

As características utilizadas neste trabalho foram nomeadas de F1 até F9. A característica F1 calcula e retorna o Índice de Forma Normalizado (NSI – *Normalized Shape Index*). O NSI caracteriza a forma de um objeto em relação a uma esfera. Uma esfera possui NSI igual a 1. Para outras formas, esse número é sempre > 1 , não necessariamente inteiro. O NSI é definido conforme

$$NSI = \frac{\frac{\sqrt{A}}{3\sqrt{V}}}{N} \quad (4.1)$$

onde A é a área do objeto e V o volume do objeto. O fator de normalização N é definido como a raiz quadrada da área da esfera dividida pela raiz cúbica do volume da esfera, de acordo com

$$N = \frac{\sqrt{4\pi R^2}}{\sqrt[3]{\frac{4}{3}\pi R^3}} = 2,199085233 \quad (4.2)$$

A área superficial (F2) é medida utilizando-se o método MUNC (*Maximum Unit Normal Component*). O volume (F3) é medido utilizando o algoritmo do teorema da divergência (DTA). Uma descrição, assim como a demonstração da acurácia e precisão desses métodos, pode ser encontrada no trabalho de ALYASSIN *et al.* [85].

As características F4, F5 e F6 medem o volume projetado em cada plano alinhado aos planos x, y ou z, respectivamente. Trata-se de considerar o volume do objeto nas direções x, y ou z.

As características F7, F8 e F9 calculam os fatores de peso para o MUNC nas direções x, y e z. O MUNC é calculado obtendo-se os vetores normais às superfícies nas direções x, y e z e obtendo-se valor máximo desses vetores normais [85].

O MATLAB (*MATrix LABoratory*) da empresa Mathworks [86] é um *software* voltado para o cálculo numérico no qual as variáveis são consideradas matricialmente. O MATLAB integra análise numérica, cálculo com matrizes, processamento de sinais, processamento de imagens e construção de gráficos, etc. O MATLAB é composto de diversos pacotes de ferramentas (*Toolbox*) tais como: *Image Acquisition Toolbox* (*aquisição de imagens*), *Image Processing Toolbox* (*processamento de imagens*). Além dessas ferramentas, o MATLAB possui diversos algoritmos implementados para aplicações utilizando redes neurais, o *Neural Network Toolbox* [75].

3 MATERIAIS E MÉTODOS

Os materiais e métodos utilizados nesta tese estão apresentados a seguir. Fez-se um detalhamento sobre os tipos de amostras utilizadas no trabalho, equipamentos, etapas de processamento e visualização de imagens tomográficas. Ao término do capítulo é descrita a metodologia proposta nesta tese para a detecção automática de defeitos em isoladores.

3.1 AMOSTRAS

Para o desenvolvimento da técnica de diagnóstico automático de defeitos por tomografia tridimensional, foram selecionados dois tipos de isoladores poliméricos utilizados em linhas de distribuição de energia: isolador tipo roldana e isolador tipo pino. Foram utilizadas amostras de isoladores poliméricos retirados de operação e um conjunto de amostras de isoladores do tipo roldana fornecido por um fabricante brasileiro.

3.1.1 ISOLADOR TIPO ROLDANA

O desenho esquemático do isolador do tipo roldana polimérico está mostrado na Figura 40. Este é utilizado para suporte e ancoragem de condutores instalados em redes de distribuição de baixa tensão e telefonia. Normalmente são produzidos em polietileno de alta densidade na cor cinza. Suporta uma tensão elétrica máxima 1,2 kV, apresenta alta resistência à tração, flexão, impacto e resistência ao trilhamento elétrico, possui boa resistência aos efeitos da radiação ultravioleta e a ruptura mecânica ocorre em 1350 kN [87].




FIGURA 40 - DESENHO ESQUEMÁTICO DO ISOLADOR POLIMÉRICO TIPO ROLDANA. MEDIDAS EM MILÍMETROS. F É A DIREÇÃO DA FORÇA APLICADA PELO CABO. FONTE: VICENTINOS DO BRASIL [87].

3.1.2 ISOLADOR TIPO PINO

O isolador de pino polimérico é utilizado em redes aéreas de distribuição compactas ou convencionais. Está mostrado, na Figura 41, um desenho esquemático com as dimensões do componente. O isolador é geralmente produzido em polietileno de alta densidade, na cor cinza, é utilizado em redes de distribuição elétrica de 15, 25 e 35 kV. Possui alta resistência a tração, flexão e impacto [87].




FIGURA 41 - DIAGRAMA ISOLADOR POLIMÉRICO TIPO PINO. AS DIMENSÕES PARA A VARIAM DE 130 MM A 180 MM, PARA B DE 140 MM A 190 MM, C DE 89 MM A 95 MM E D=45 MM. FONTE: VICENTINOS DO BRASIL [87].

3.2 EQUIPAMENTOS UTILIZADOS

Os equipamentos utilizados no desenvolvimento do trabalho, como detectores, geradores de raios X e a mesa tomográfica industrial estão apresentados a seguir. Dois sistemas de aquisição de radiografias industriais foram utilizadas na aquisição e reconstrução das tomografias. Um sistema de radioscopia industrial com intensificador de imagens acoplado a uma câmera de TV, modelo CHF 160S, do fabricante Gilardoni (Figura 42 e Figura 43) e um sistema digital direto com detector de a-Si (*flat panel*) conforme estão mostradas nas Figura 44 e Figura 45.

3.2.1 SISTEMA RADIOSCÓPICO

O diagrama do equipamento radioscópico utilizado na aquisição das tomografias dos isoladores tipo pino pode ser visualizado na Figura 42. Esse sistema de radioscopia (Figura 42) é composto por: gerador de raios X milifoco de 0,4 mm x 0,4 mm, intensificador de imagens (Figura 43), câmera CCD do fabricante Samsung, modelo BW-2302, que fornece imagens em *Bitmap* de 640 x 480 *pixels* (cada *pixel* com 290 μm), campo de visão de 9" (23 cm de diâmetro), mesa tomográfica com sistema de rotação com motor DC de microposicionamento da

Physics Instruments controlado por placa ISA (*Industry Standard Architecture*), unidade de controle e microcomputador.




FIGURA 42 - SISTEMA DE RADIOSCOPIA. FONTE: O AUTOR.



FIGURA 43 - DETALHE DO INTENSIFICADOR DE IMAGENS DO SISTEMA DE RADIOSCOPIA MOSTRADO NA FIGURA 42. FONTE: O AUTOR.

3.2.2 SISTEMA DIGITAL DIRETO

O diagrama do equipamento de radiografia digital direta, utilizado na aquisição das tomografias dos isoladores tipo roldana, pode ser visualizado na

Figura 44. Esse sistema é composto por gerador de raios X microfoco (0,01 mm x 0,01 mm) do fabricante *KeveX X-Ray Inc*, detector digital direto de raios X de 12 bits da HAMAMATSU CT 7942 que está acoplado a uma placa *Frame Grabber* de aquisição modelo NI/IMAQ PCI1422 da *National Instruments* e possui dimensões de 12 cm x 11 cm (Figura 45), resolução de 2400 x 240 pixels (cada pixel com dimensão de 50 µm), unidade de controle e computador.




FIGURA 44 - SISTEMA DIGITAL DIRETO COM DETECTOR A-SI (FLAT PANEL). PARA FUNCIONAMENTO, A FONTE DE RAIOS X MICROFOCO FUNCIONA COM 12 VDC NA ENTRADA. O DETECTOR DIGITAL DIRETO POSSUI ÁREA ATIVA DE 12 CM X 11 CM E ESTÁ LIGADO AO COMPUTADOR POR UMA PLACA PCI. FONTE: O AUTOR.




FIGURA 45 – DETALHE DE DETECTOR DIGITAL DE RAIOS X (FLAT PANEL). FONTE: O AUTOR.

Está mostrada na Figura 46 o arranjo experimental utilizado na aquisição das tomografias dos isoladores tipo roldana.




FIGURA 46 - ARRANJO EXPERIMENTAL UTILIZADO NA AQUISIÇÃO DAS TOMOGRAFIAS NO SISTEMA DIGITAL DIRETO. FONTE: O AUTOR

Está mostrada na Figura 47 a fonte microfoco utilizada com o sistema digital direto.



FIGURA 47 - GERADOR DE RAIOS X MICROFOCO UTILIZADO NO SISTEMA DIGITAL DIRETO. FONTE: O AUTOR.

A Tabela 2 apresenta um quadro comparativo dos dois sistemas radiográficos utilizados nesta tese.

TABELA 2 - CARACTERÍSTICAS DOS SISTEMAS DE RADIOGRAFIA INDUSTRIAL UTILIZADOS.
FONTE: O AUTOR.

ITEM	SISTEMA RADIOSCÓPICO	SISTEMA DIGITAL DIRETO
Tamanho do Foco	Minifoco 0.4 x 0.4 mm ²	Microfoco 10 x 10 μm ²
Janela	Be	Be (125 μm)
Alvo	W	W
Faixa de Tensão	10 a 160 kV	20 a 70 kV
Faixa de Corrente	0 a 10 mA	0 a 0,1 mA
Resolução espacial	640 x 480 pixels	2400 x 2400 pixels
Binning	Não	Sim (2x2, 4x4)
Trigger	Não	Sim (Int e Ext)
Tamanho do Pixel	290 μm	50 μm
Saída Digital	8 bits	12 bits

Para as amostras de isoladores tipo roldana, as radiografias foram obtidas utilizando o gerador de raios X microfoco (com 70 kV, 0,01 mA). As imagens foram adquiridas com 5 e 7 s de tempo de integração no detector digital plano e a distância fonte-detector foi de 80 cm e distância objeto-detector de 8 cm. As imagens dos isoladores tipo pino foram obtidas no sistema de radioscopia que utilizou a fonte de raios X tipo milifoco, com 70 kV de tensão aplicada no gerador e 1,0 mA de corrente e distância fonte-detector de 80 cm. Esses parâmetros foram utilizados posteriormente para a obtenção das tomografias 2D.

3.3 FERRAMENTAS DE DESENVOLVIMENTO E PRÁTICAS COMPUTACIONAIS UTILIZADAS

Foram utilizadas as seguintes ferramentas computacionais para o desenvolvimento deste trabalho:

- A ferramenta computacional utilizada para a reconstrução das fatias tomográficas bidimensionais foi desenvolvida em C++ por PIEKARZ [31] como parte de sua dissertação de mestrado. É mostrada na Figura 48 a interface da ferramenta computacional.
- A ferramenta para desenvolvimento do software de reconstrução de tomografias 3D industriais e quantificação dos objetos 3D foi o VTK em IDE Netbeans, em sistema operacional LINUX.
- As redes neurais utilizadas nesta tese foram treinadas e testadas no *Toolbox* de Redes Neurais do *software* MATLAB versão R2011a. D

uas redes neurais foram utilizadas, a saber, a *feedforward backpropagation* supervisionada e a rede SOM.

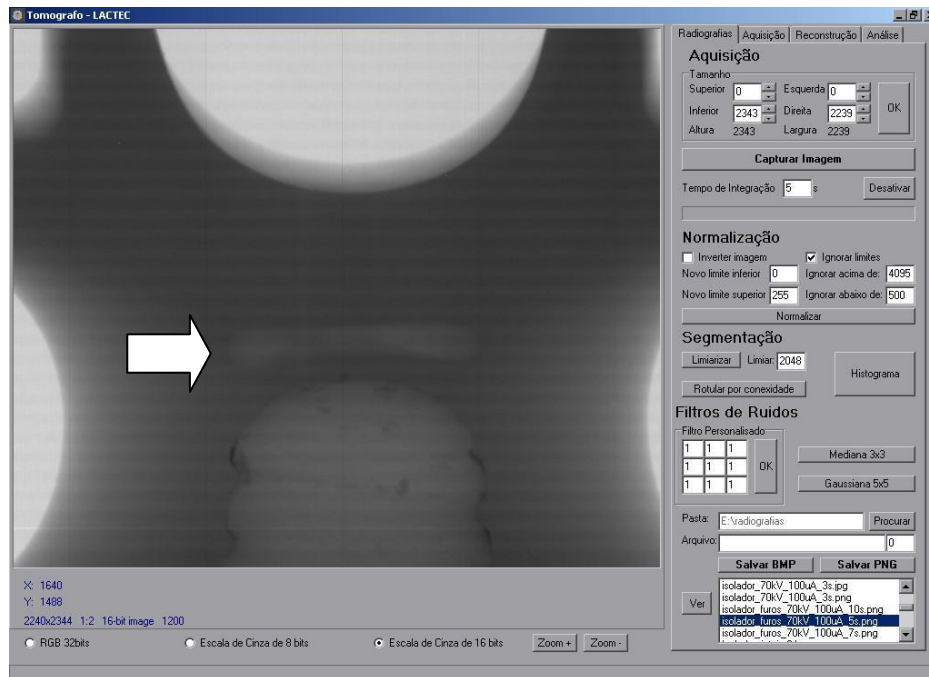


FIGURA 48 - INTERFACE COM O USUÁRIO DA FERRAMENTA COMPUTACIONAL DE RECONSTRUÇÕES DE TOMOGRAFIAS 2D. A IMAGEM MOSTRA A RADIOGRAFIA DE UM ISOLADOR TIPO PINO COM BOLHA INTERNA (SETA). FONTE: PIEKARZ [31].

3.4 LEVANTAMENTO DE CARACTERÍSTICAS 3D COMO DADOS DE ENTRADA PARA RECONHECIMENTO DE PADRÕES

As características tridimensionais dos objetos reconstruídos na tomografia 3D foram calculadas utilizando-se a classe `vtkMassProperties` do VTK [84,88,85,89]. A Tabela 3 resume as 9 características calculadas (denominadas F1 até F9).

TABELA 3 - CARACTERÍSTICAS (F1 ATÉ F9) CALCULADAS DOS OBJETOS 3D TOMOGRÁFICOS RECONSTRUÍDOS. TODAS SÃO CARACTERÍSTICAS DE NATUREZA GEOMÉTRICA. FONTE: O AUTOR.

Característica	Nome	Descrição
F1	Índice de Forma	Calcula e retorna o NSI
F2	Área superficial	Área superficial do objeto ($pixel^2$)
F3	Volume	Volume do objeto ($pixel^3$)
F4	Vx	Volume do objeto projetado no plano alinhado ao eixo x
F5	Vy	Volume do objeto projetado no plano alinhado ao eixo y
F6	Vz	Volume do objeto projetado no plano alinhado ao eixo z
F7	Kx	Valor MUNC na direção x
F8	Ky	Valor MUNC na direção y
F9	Kz	Valor MUNC na direção z

Após a extração das características dos objetos encontrados renderizados nas tomografias tridimensionais dos isoladores (reconstruídas por *Marching Cubes* de acordo com limiar definido para a interface ar-polímero) realizaram-se o treinamento, teste e validação de uma rede neural retropropagada com 20 neurônios na subcamada no intuito de detectar automaticamente defeitos presentes nos isoladores. As entradas da rede neural corresponderam a 50 amostras (isossuperfícies) com 9 características levantadas de cada uma (F1 até F9). Os dados de saída (pesos sinápticos) permitem a detecção automática dos defeitos dos isoladores.

3.4 FLUXOGRAMA DO TRABALHO

O fluxograma para o desenvolvimento deste trabalho está mostrado na Figura 49. A primeira etapa consistiu em adquirir 180 projeções radiográficas. A partir dessas projeções, retira-se uma linha de cada projeção, monta-se o senograma e realizar o processamento para reconstrução da tomografia bidimensional (fatias tomográficas de 8 *bits* no formato *Bitmap*, 256 tons de cinza). Existiram dois caminhos que puderam ser seguidos antes da reconstrução tomográfica 3D a partir das fatias obtidas: (a) ou segmentar cada fatia tomográfica no intuito de separar o objeto de interesse (a partir de filtros de segmentação que, no caso, está sendo feito com a técnica de limiarização global, em linguagem C++ com a biblioteca ITK (*Insight Toolkit*) ou; (b) aplicar diretamente o valor de limiarização da superfície ou volume nas fatias para reconstrução tomográfica 3D.

Na sequência, para a detecção automática de defeitos nos isoladores, fez-se o levantamento de nove características tridimensionais de cada objeto reconstruído nas tomografias 3D renderizadas por *Marching Cubes* (objetos isolados) e após treinamento, teste e validação das redes neurais utilizadas.

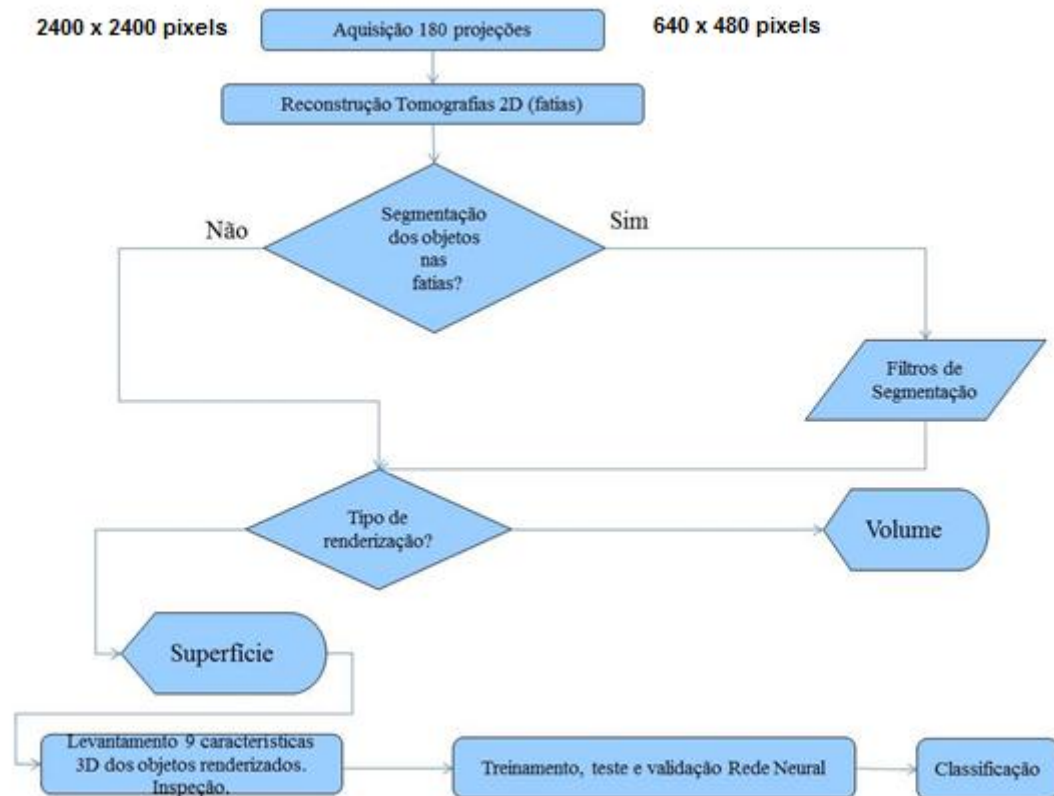


FIGURA 49 - FLUXOGRAMA DO TRABALHO DESENVOLVIDO. FONTE: O AUTOR.

4 DESENVOLVIMENTO DA MESA TOMOGRÁFICA INDUSTRIAL

A mesa tomográfica foi parte da instrumentação desenvolvida e utilizada nesta tese. Por ser instrumento primordial em tomografia industrial e pela dificuldade que se tem de adquirir no mercado equipamentos tomográficos para aplicações industriais (seja pelos custos ou pelo não atendimento de demanda do produto para dada aplicação), foi desenvolvido um protótipo de mesa tomográfica que permitiu a aquisição das imagens radiográficas digitais (as projeções) no detector digital de raios X. A descrição detalhada desse sistema, com toda a instrumentação desenvolvida, está apresentada a seguir.

4.1 SISTEMA MECÂNICO DA MESA TOMOGRÁFICA

O carro de suporte da amostra é um componente que teve a função de prover os movimentos de rotação, translação vertical e translação horizontal da amostra de forma automática. O componente foi composto de um carro principal que se desloca sobre a estrutura mecânica apoiado no cavalete principal (Figura 50). Dois fusos acoplados a motores de passo, sendo um responsável pela elevação e outro pelo deslocamento horizontal, atuaram na mesa giratória que suporta a amostra.




FIGURA 50 - PROJETO CAD DA MESA TOMOGRÁFICA: COMPONENTE RESPONSÁVEL PELOS DESLOCAMENTOS VERTICAL, HORIZONTAL E DE ROTAÇÃO DA AMOSTRA. FONTE: O AUTOR.

Na Figura 51 está mostrado o modelo das polias de sincronização dos fusos de elevação. Um terceiro motor de passo inicialmente foi projetado para atuar diretamente no movimento de rotação da mesa. No entanto, a precisão necessária não foi adequada com a utilização do motor de passo. Assim, o motor de um sistema de tomografia industrial da marca Gilardoni foi adaptado à mesa. Os mecanismos são apoiados em guias esféricas e rolamentos para redução do atrito e precisão do posicionamento.




FIGURA 51 - POLIAS DE SINCRONIZAÇÃO DOS FUSOS DE ELEVAÇÃO DA MESA TOMOGRÁFICA. FONTE: O AUTOR.

O carro principal foi suportado por guias lineares na estrutura da mesa (Figura 52) e pode ser posicionado manualmente com curso total de 1300 mm. Os deslocamentos vertical e horizontal apresentaram curso total de 250 mm e o movimento rotacional bidirecional é ilimitado.




FIGURA 52 - PROJETO CAD DA MESA TOMOGRÁFICA EM SUA COMPOSIÇÃO TOTAL. FONTE: O AUTOR.

Após a conclusão da estrutura mecânica da mesa tomográfica foram confeccionados dois suportes para a fixação da fonte de raios X e do detector plano de raios X. Na Figura 53 está mostrada uma fotografia da mesa tomográfica com a fonte microfoco de raios X fixada no suporte (lado direito) e o detector digital plano de raios X (*flat panel*) também fixado no seu suporte (lado esquerdo).




FIGURA 53 - PROTÓTIPO COM A FONTE DE RAIOS X (LADO DIREITO) E DETECTOR DIGITAL PLANO DE RAIOS X (LADO ESQUERDO). FONTE: O AUTOR.

As peças, tais como as guias lineares, as guias esféricas, fusos de deslocamento e de elevação, polias de sincronismo e correia, foram adquiridas de fabricantes nacionais. As peças restantes foram usinadas.

4.2 DESENVOLVIMENTO DA INTERFACE COM O COMPUTADOR

A interface da mesa tomográfica para testes de movimentos com o comando do computador foi desenvolvida utilizando o *software* LABVIEW. Após foi utilizado interface de controle desenvolvido em C++.

Os comandos elétricos para acionamento dos motores de passo e leitura dos sinais dos sensores fim de curso foram realizados por meio da porta paralela do computador. Para compatibilizar os sinais elétricos utilizados pela porta paralela do computador com os sinais para acionamento dos motores de passo e sensores fim de curso, foi desenvolvido circuito eletrônico utilizando opto-acopladores. Esses circuitos ficaram fixados em uma placa projetada e desenvolvida e instalada num painel de comando montado junto à mesa tomográfica. Na Figura 54 é mostrada o painel de comando da mesa tomográfica disposto atrás do suporte do detector plano.



FIGURA 54 - PAINEL DE COMANDO DA MESA TOMOGRÁFICA. FONTE: O AUTOR.

A interligação entre o painel e o computador foi feita com um cabo multivias com aproximadamente cinco metros, o que possibilitou deixar o computador a uma distância segura da mesa tomográfica (outra sala), lembrando-se que para a operação com raios X é necessário que o sistema tomográfico fique em uma sala blindada, protegendo o operador das radiações ionizantes.

A placa foi composta de 12 optoacopladores modelo OP4N25A e foi instalada no painel elétrico de comando. Os cabos estão todos conectados por meio de borneiras fixadas na própria placa conforme mostrado na Figura 55. Cada circuito optoacoplador teve a função de compatibilizar os sinais que saem do computador (enviados por meio do aplicativo de controle) com a função de acionar determinado relé auxiliar no painel e o sinal de pulso para os drivers, como também os sinais dos sensores de fim de curso presentes na máquina que são enviados ao *software* de controle.

Os optoacopladores na placa foram numerados de 1 a 12 (Figura 55) e distribuídos para executar a transferência dos sinais de acordo com relação da Tabela 4.




FIGURA 55 - PLACA COM OS CIRCUITOS OPTOACOPLADORES. FONTE: O AUTOR.

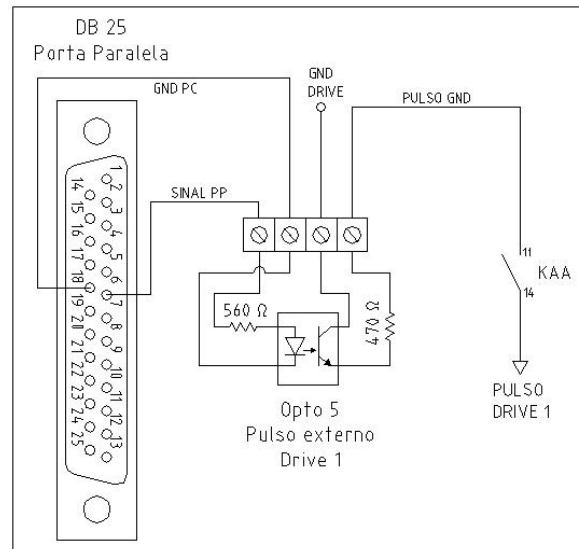


FIGURA 57 - DIAGRAMA ELETRÔNICO DO DISPOSITIVO OPTOACOPLADOR PARA ACIONAMENTO DO DRIVE DO MOTOR DE PASSO. FONTE: O AUTOR.

Os optoacopladores numerados de 9 a 12 foram montados com uma configuração para monitorar os estados dos sensores fim de curso, os quais limitam os movimentos horizontal (movimento X) e vertical (movimento Y) do carro principal da mesa tomográfica. O diagrama eletrônico está apresentado na Figura 58.

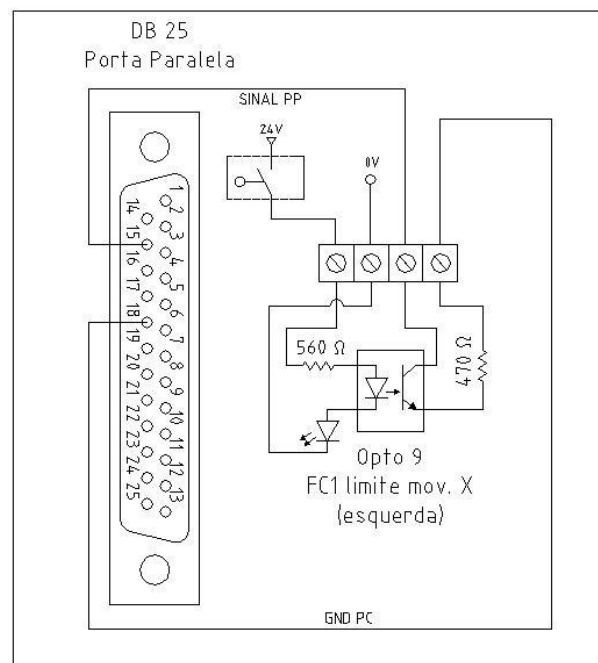


FIGURA 58 - DIAGRAMA ELETRÔNICO DO DISPOSITIVO OPTOACOPLADOR PARA LEITURA DOS SINAIS DOS SENSORES FIM DE CURSO. FONTE: O AUTOR.

Para acionamento da potência e controle dos motores foram utilizados três conversores bipolares de micro passo modelo TPH3020 adquiridos no mercado.

Esses foram instalados no painel de comando. As características operacionais do TPH3020 são:

- Tensão de alimentação de 10 a 24 Vac ou de 12 a 30 Vdc;
- Ponte retificadora interna;
- Controle por pulso, direção e habilitação;
- Controle de redução de corrente;
- Configurável em 200, 400, 800 e 1600 passos por revolução.

Os dois conversores que controlam os motores para os movimentos horizontal e vertical foram configurados para 400 passos por revolução, ou seja, o motor gira 0,9 graus por passo. Já, o conversor que controla o motor do movimento da mesa foi configurado para operar em 1600 passos, ou seja, o motor gira 0,225 graus por passo.

4.3 MODOS DE OPERAÇÃO DO SISTEMA DE AQUISIÇÃO TOMOGRÁFICO

Os modos de operação do equipamento podem ser descritos da seguinte forma. No painel de comando montado junto à mesa tomográfica encontram-se os componentes para as operações básicas do sistema. Na parte lateral do painel de comando, visto na Figura 59, está localizada a chave seccionadora geral, que possui duas posições: na posição zero (0) o painel está sem alimentação e na posição um (1) o painel é energizado acendendo a lâmpada de sinalização (ligado).



FIGURA 59 - VISTA LATERAL DO PAINEL DE COMANDO. FONTE: O AUTOR.

Na parte frontal do comando (porta) encontram-se a botoeira de emergência com retenção e a chave seletora de modo de operação manual e automático conforme mostrado na Figura 60.



FIGURA 60 - VISTA DO PAINEL DE COMANDO COM CHAVE SELETORA PARA MANUAL OU AUTOMÁTICO. FONTE: O AUTOR.

A botoeira de emergência, quando acionada, corta os acionamentos elétricos da mesa desativando a operação dos motores. A chave seletora de modo de operação possui três posições descritas a seguir:

1. Automático - Nessa situação a mesa encontra-se habilitada para ser operada por meio da ferramenta de controle LABVIEW. Isso é permitido pelo intertravamento na chave seletora de comando que habilita um conjunto de relés auxiliares, que, ao receberem os sinais de comando do software de controle, executarão suas respectivas funções.
2. Manual - Quando no modo Manual, a mesa pode ser operada por meio de um controle *joystick*. Esse controle possui os seguintes comandos: sobe, desce, esquerda, direita e giro da mesa no sentido horário e anti-horário (Figura 61).
3. Desligado – Posição Zero (0) desabilita todos os comandos. O painel permanece no estado *standby* esperando uma ação do operador.




FIGURA 61 - JOYSTICK PARA MOVIMENTAÇÃO MANUAL DA MESA. FONTE: O AUTOR.

Essas operações dependem do intertravamento com os relés de operação. Na Figura 62 é mostrado o diagrama elétrico do intertravamento da chave.

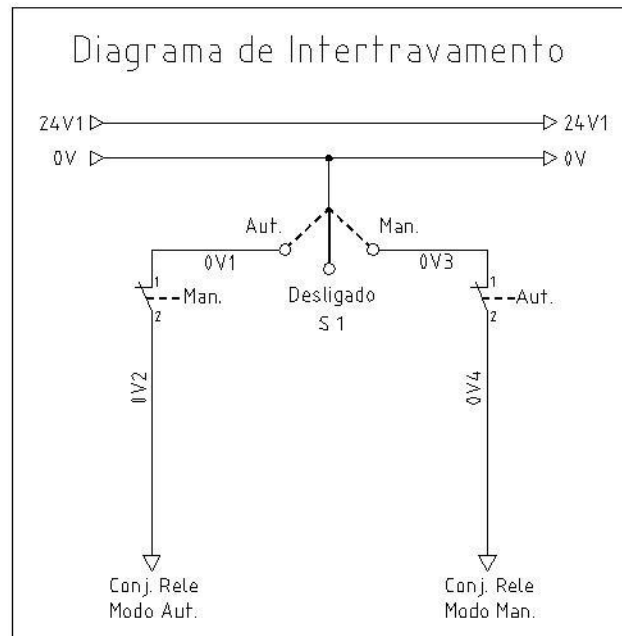


FIGURA 62 - DIAGRAMA ELÉTRICO DO INTERTRAVAMENTO DA CHAVE SELETORA. FONTE: O AUTOR.

Na Figura 63 estão mostrados os componentes do painel de comando. Na Tabela 5 está mostrada descrição de cada um deles.



FIGURA 63 - COMPONENTES DO PAINEL DE COMANDO. FONTE: O AUTOR.

TABELA 5 - DESCRIÇÃO DOS COMPONENTES INTERNOS DO PAINEL DE COMANDO DA FIGURA 61. FONTE: O AUTOR.

Item	Componente	Função	Qtde
1	Placa eletrônica	Interface porta paralela com PC mesa	01
2	Chave seletora de comando	Seleciona os modos: manual, automático ou <i>standby</i>	01
3	Botão de emergência	Interrupção da tensão dos acionamentos elétricos	01
4	Fonte de tensão 24 V DC	Fonte dos dispositivos de alimentação do detector digital de raios X	01
5	Fonte de tensão 5A, 24 V DC	Fornecer alimentação de 24 V DC	01
6	Bornes para fusível	Proteção curto-circuito	03
7	Disjuntor bipolar 10 A	Proteção curto-circuito e sobrecarga	01
8	Seccionadora geral	Manobra de alimentação elétrica painel de comando	01
9	Conversor (driver) motor de passo	Alimentação e controle motores de passo	03
10	Régua de bornes	Interface com componentes externos	18
11	Ventilador	Ventilar internamente o painel	01
12	Relé de interface 6,2 mm	Interface e isolamento elétrico entre modos de comando	14

4.4 TESTES PARA RECONSTRUÇÃO DE TOMOGRAFIAS 2D

Para verificar o funcionamento dos motores em relação aos controles de movimentos de rotação da mesa, ou seja, se o passo da mesa tomográfica está correspondendo adequadamente ao algoritmo de reconstrução de fatias, realizou-se um teste numa amostra padrão de acrílico com furos com dimensões conhecidas (*phantom*) conforme mostrado na Figura FIGURA 64. A ferramenta computacional utilizado para a reconstrução das fatias tomográficas (tomografias 2D) é uma versão desenvolvida por PIEKARZ [31]. Na Figura 65a está mostrada a imagem obtida quando foram enviados 8 pulsos pela porta paralela para o motor de passo que controla o movimento de rotação da mesa. Nesse modo houve artefatos. A imagem tomográfica corretamente reconstruída está mostrada na Figura 65b. Para a reconstrução dessa tomografia o passo de movimento utilizado foi 0,9 graus (o que equivale a enviar 9 pulsos pela porta paralela para o motor de passo), sendo que o controle para 1 grau no motor de passo foi inviável, pois não há precisão para isso. O motor responsável pela rotação também mostrou que estava aquecendo muito.

Inicialmente pensou-se em utilizar o motor de passo para rotar a mesa tomográfica. Como será explicado na próxima seção, isso foi alterado.






FIGURA 64: FOTO PHANTOM DE ACRÍLICO COM FUROS DE 1 MM A 6 MM.
FONTE: O AUTOR.



a



b

FIGURA 65 - TOMOGRAFIA DE UM PHANTOM DE ACRÍLICO. (A) UTILIZANDO 8 PULSOS NO MOTOR DE PASSO PARA ROTACIONAR A MESA E (B) UTILIZANDO 9 PULSOS (OU PASSO DE 0,9 GRAUS). FONTE: O AUTOR.

4.1.1 ALTERAÇÕES NO PROJETO ORIGINAL

O motor de passo responsável por rotar a mesa foi substituído pelo motor da mesa do sistema de tomografia Gilardoni, do fabricante *Physical Instruments*, mais

preciso, sendo mantidos todos os outros motores para os movimentos horizontais e verticais da mesa.

A justificativa para a alteração do motor de movimento de rotação da mesa veio de um teste experimental com a ferramenta computacional de aquisição de tomografias de PIEKARZ [31]: pulsos enviados pela porta paralela versus deslocamento medido. O programa envia uma quantidade de pulsos para que a mesa gire 9 graus a cada comando. Esse procedimento foi repetido 40 (quarenta) vezes e anotou-se o valor real da rotação em graus na escala de rotação da mesa tomográfica. Os resultados estão apresentados na Tabela 6.

Os erros encontrados para a movimentação dos motores em testes nos eixos horizontal X e vertical Y variaram de 5 % a 8%. Esses valores podem inviabilizar ou dificultar o registro de duas ou mais imagens automaticamente. No entanto, apenas para movimentos manuais de posicionamento da peça não são restritivos.

TABELA 6 - RESULTADOS DAS MEDIDAS OBTIDAS PARA TESTES DE ROTAÇÃO DA MESA UTILIZANDO O MOTOR DE PASSO. FONTE: O AUTOR.

Deslocamento padrão (graus)	Deslocamento medido (graus)	Erro (%)
0,0	0,0	0
9,0	9,2	2,2
18,0	18,2	1,1
27,0	27,3	1,1
36,0	36,3	0,8
45,0	45,3	0,7
54,0	54,1	0,2
63,0	63,3	0,5
72,0	72,6	0,8
81,0	81,8	1,0
90,0	90,8	0,9
99,0	99,8	0,8
108,0	108,9	0,8
117,0	118,0	0,9
126,0	127,3	1,0
135,0	136,4	1,0
144,0	145,6	1,1
153,0	154,8	1,2
162,0	163,9	1,2
171,0	173,0	1,2
180,0	182,1	1,2
189,0	191,6	1,4
198,0	200,3	1,2
207,0	209,3	1,1
216,0	218,3	1,1
225,0	227,8	1,2
234,0	236,8	1,2
243,0	245,8	1,2
252,0	255,0	1,2
261,0	264,1	1,2
270,0	273,3	1,2
279,0	282,3	1,2
288,0	291,3	1,1
297,0	300,3	1,1
306,0	309,3	1,1
315,0	318,3	1,0
324,0	327,3	1,0
333,0	336,7	1,1
342,0	345,7	1,1
351,0	354,7	1,1
360,0	363,7	1,0

O protótipo de mesa tomográfica desenvolvido neste trabalho permitiu a execução de ensaios de radiografias e tomografias de componentes elétricos e também de outros componentes manufaturados. A movimentação de translação da mesa permitiu ampliar a área de aquisição de imagens para inspeção radiográfica em até quatro vezes, o que implica em redução de custos para um sistema como esse, e do fato de que detectores com maior área útil apresentam menor resolução espacial com tamanho de *pixel* superiores a 200 μm . Para a realização de tomografias, as dimensões do objeto não puderam ser superiores às dimensões do detector digital plano de raios X (120 mm x 110 mm). Assim, neste novo sistema, apenas isoladores tipo roldana foram radiografados. As imagens radiográficas de isoladores tipo pino foram feitas no sistema de radioscopia. Outro ponto favorável é

que os componentes elétricos e eletrônicos utilizados no projeto da mesa foram adquiridos no mercado nacional.

5 RESULTADOS E DISCUSSÕES

Neste capítulo estão apresentados os resultados obtidos nesta tese. Inicialmente, apresentam-se imagens das aquisições das radiografias obtidas pelo detector digital plano de raios X para isoladores tipo roldana. Na sequência apresentam-se as imagens obtidas no intensificador de imagens para isoladores tipo pino. Objetiva-se, desta forma, mostrar as características dessas imagens e sua importância na formação das imagens tomográficas 2D e 3D, que são apresentadas na sequência. Finalizando, apresentam-se os resultados e discussões para o treinamento e teste da rede neural SOM e da rede neural supervisionada retropropagada.

5.1 AQUISIÇÃO DE RADIOGRAFIAS DIGITAIS

Nesta seção apresentam-se imagens das aquisições das radiografias obtidas pelo detector digital de raios X *direto (flat panel)* para isoladores tipo roldana. As imagens obtidas com o intensificador de imagens do tomógrafo do fabricante Gilardoni para isoladores tipo pino também são apresentadas. A radiografia é a primeira imagem adquirida para definição de parâmetros de aquisição que servirão para a realização das tomografias. Essas aquisições são necessárias também, para caracterizar e compreender os resultados encontrados nas imagens tomográficas 3D. Mostram-se, como resultado, as principais características das projeções adquiridas pelos dois sistemas utilizados nesta tese, tais como artefatos, forma dos defeitos encontrados, etc.

5.1.1 RADIOGRAFIAS ISOLADORES TIPO ROLDANA

As imagens radiográficas das Figuras 66 a 71 são referentes a isoladores do tipo roldana com defeitos. A Figura 66 mostra a radiografia de um isolador tipo roldana apresentando impurezas de material em sua composição (região escura indicadas na radiografia) e o artefato tipo estrela que é gerado pelo detector digital.




FIGURA 66 - RADIOGRAFIA DE ISOLADOR ROLDANA COM IMPUREZAS NO MATERIAL E ARTEFATO TIPO "ESTRELA". PARÂMETROS DE AQUISIÇÃO: 70KV, 0,01 MA, 5 S. FONTE: O AUTOR.

A Figura 67 mostra a radiografia de um isolador tipo roldana apresentando bolha em sua estrutura (região clara indicada na figura). Pode-se ver também o artefato tipo estrela conforme indicada na figura.




FIGURA 67 – RADIOGRAFIA DE ISOLADOR ROLDANA COM DEFEITO (BOLHA). PARÂMETROS DE AQUISIÇÃO: 70KV, 0,01 MA, 5 S. FONTE: O AUTOR.

A Figura 68 mostra a radiografia de um isolador tipo roldana apresentando impurezas de material e artefato tipo estrela.




FIGURA 68 - RADIOGRAFIA DE ISOLADOR ROLDANA COM DEFEITO (IMPUREZAS NO MATERIAL). PARÂMETROS DE AQUISIÇÃO: 70KV, 0,01 MA, 5 S. FONTE: O AUTOR.

A Figura 69 mostra a radiografia de um isolador tipo roldana apresentando impurezas de material e artefato tipo estrela (indicações na figura).




FIGURA 69 - RADIOGRAFIA DE ISOLADOR ROLDANA COM DEFEITO (IMPUREZAS NO MATERIAL). PARÂMETROS DE AQUISIÇÃO: 70KV, 0,01 MA, 5 S. FONTE: O AUTOR.

A Figura 70 mostra a radiografia de um isolador tipo roldana apresentando impurezas de material (indicações na figura).




FIGURA 70 - RADIOGRAFIA DE ISOLADOR ROLDANA COM DEFEITO (IMPUREZAS NO MATERIAL). PARÂMETROS DE AQUISIÇÃO: 70KV, 0,01 MA, 5 S. FONTE: O AUTOR.

A Figura 71 mostra radiografia e uma tomografia 2D (fatia) de uma amostra de isolador tipo roldana com bolhas em seu interior.




FIGURA 71 - (A) RADIOGRAFIA DE ISOLADOR TIPO ROLDANA. PARÂMETROS DE AQUISIÇÃO: 70KV, 0,01 MA, 5 S . (B) FATIA TOMOGRÁFICA APRESENTANDO BOLHAS. NA IMAGEM PODE-SE VER 5 BOLHAS INDICADAS PELAS SETAS. FONTE: O AUTOR.

5.1.2 RADIOGRAFIA ISOLADORES TIPO PINO

Além das amostras de isoladores tipo roldana, também foram utilizadas imagens radiográficas de isoladores tipo pino, no intuito de avaliar os defeitos nos componentes. As imagens radiográficas dos isoladores tipo pino foram obtidas utilizando um intensificador de imagens, pois o campo de visão do *flat panel* é dimensionalmente menor que o componente a ser analisado. Foram realizadas

radiografias de diferentes fabricantes de isoladores tipo pino que foram retirados da rede de distribuição de energia. Na Figura 72, está mostrada uma radiografia de um isolador, com bolhas, obtida no intensificador de imagens.




FIGURA 72 - RADIOGRAFIA DE ISOLADOR TIPO PINO OBTIDA EM SISTEMA COM INTENSIFICADOR DE IMAGENS DA FIGURA 42. AS SETAS INDICAM DUAS BOLHAS. FONTE: O AUTOR.

5.2 TOMOGRAFIAS 3D DE ISOLADORES

Como parte desta tese desenvolveu-se uma ferramenta computacional para reconstrução das tomografias 3D aplicadas a isoladores poliméricos denominado LACVIS. Esse protótipo de *software* tem a função de fazer a reconstrução tridimensional de superfícies e volumes a partir de fatias tomográficas geradas e ainda permite obter características espaciais dos objetos reconstruídos a partir de levantamento de parâmetros das superfícies reconstruídas pela técnica de visualização *Marching Cubes*. O sistema operacional utilizado foi o Ubuntu Linux 64 Bits, desenvolvido em linguagem Java com a IDE NetBeans da Oracle, na qual foi incorporada a biblioteca *Open Source VTK* utilizando as classes de funções presentes no arquivo `vtk.jar`. As tomografias bidimensionais utilizadas para

reconstrução 3D foram obtidas pela ferramenta desenvolvida por PIEKARZ [31]. A Figura 73 apresenta a interface do aplicativo LACVIS.




FIGURA 73 - INTERFACE SOFTWARE LACVIS: INTERFACE COM O USUÁRIO DA FERRAMENTA COMPUTACIONAL DE RECONSTRUÇÃO DE TOMOGRAFIAS 3D NO SISTEMA OPERACIONAL LINUX 64 BITS. A IMAGEM PRESENTE É A DA TOMOGRAFIA 3D DE UM ISOLADOR POLIMÉRICO TIPO ROLDANA. FONTE: O AUTOR.

A possibilidade de isolar os objetos reconstruídos (defeitos e não defeitos) e a partir deles obter características mensuráveis é essencial para o desenvolvimento de uma metodologia de reconhecimento de padrões tridimensionais nas tomografias dos isoladores. A ferramenta computacional desenvolvida, além da implementação dos algoritmos de reconstrução de imagens, contém algoritmos que realizam a extração das características 3D quantitativas dos objetos de imagem. As características principais desta ferramenta foram:

1. possibilitar a reconstrução de tomografias tridimensionais a partir de fatias 2D em formato Bitmap;
2. utilizar dois métodos de reconstrução tridimensional: por volume (*Ray Casting*) e superfície (*Marching Cubes*), implementados com a biblioteca VTK;

3. possibilitar a utilização de filtros tridimensionais como o filtro gaussiano ou o filtro da mediana com o objetivo de suavizar a superfície reconstruída;
4. permitir fazer o levantamento de características (tais como volume, a área superficial, forma esfera, etc) de todos os objetos reconstruídos pelo *Marching Cubes*. Esses parâmetros são armazenados num arquivo ASCII;
5. exportar a malha no formato STL (Stereolitografia).

A Figura 74 mostra um exemplo de tela da ferramenta computacional desenvolvida e denominada LACVIS, para o cálculo de características para o isolador tipo pino. Devido à fácil implementação dos métodos da classe `vtkMassProperties` e por ser desconhecido os aspectos relevantes das características para reconhecimento 3D de objetos tomográficos, foram utilizados todos os métodos da classe para calcular características extraídas das iso-superfícies renderizadas para treinamento da rede neural. Somente após estudou-se, por correlação, as características mais significativas para a detecção dos defeitos nos isoladores, conforme será visto na sequência.

O cálculo das características ocorreu de forma iterativa, desde o primeiro objeto-superfície encontrado na tomografia, reconstruído a partir do limiar escolhido no algoritmo de *Marching Cubes*, até o último objeto presente. Os dados calculados foram armazenados em um arquivo ASCII para posterior utilização no teste e treinamento das redes neurais utilizadas. O objeto presente na Figura 74 será denotado como Estrutura Regular (ER), ou -1 na matriz do vetor de entrada no treinamento supervisionado. Em contrapartida, quando se tratar de uma bolha, como mostrado na Figura 75, será marcado como Defeito (D), ou + 1, no vetor de entrada. Na rede SOM, apesar de conhecidos, não é utilizado a denominação da ER e D no vetor de entrada. Os dados são mostrados na Tabela B1 do Apêndice B.



FIGURA 74 - RENDERIZAÇÃO SUPERFÍCIE DO ISOLADOR TIPO PINO E CARACTERÍSTICAS CALCULADAS PELO LACVIS DE F1 ATÉ F9. FONTE: O AUTOR.




FIGURA 75 - RENDERIZAÇÃO DE BOLHA INTERNA DO ISOLADOR MOSTRADO NA FIGURA 74 E AS CARACTERÍSTICAS CALCULADAS PELO LACVIS DE F1 ATÉ F9. FONTE: O AUTOR.

A ferramenta computacional permite ao usuário decidir que tipo de renderização ele deseja visualizar (volume ou apenas a superfície dos objetos na

tomografia). Se a escolha for renderização de superfície, é possível obter nove características 3D dos objetos renderizados e estas podem ser utilizadas para treinamento, teste e validação da rede neural, no intuito de classificar defeito (D) ou estrutura regular (ER). A Figura 76 mostra o resultado da reconstrução da imagem tridimensional de um isolador do tipo pino e o relatório da extração das características da imagem na tela para cada objeto reconstruído (no caso um isolador tipo pino). O resumo do código fonte da interface mostrada aqui está disponível no Apêndice A em linguagem Java.



FIGURA 76 - RECONSTRUÇÃO TRIDIMENSIONAL DE UM ISOLADOR TIPO PINO POR *MARCHING CUBES* E LISTAGEM DE CARACTERÍSTICAS MEDIDAS QUE APARECEM NA TELA, JUNTAMENTE COM O NÚMERO DO OBJETO RECONSTRUÍDO. FONTE: O AUTOR.

A Figura 77 mostra a reconstrução tridimensional das superfícies de um isolador tipo roldana. Utilizando o algoritmo de *Marching Cubes*. Deve-se definir um limiar de tom de cinza nas tomografias para que seja renderizada apenas a superfície polimérica do componente (interface ar-polímero) pelo *Marching Cubes*. Para as tomografias dos isoladores (imagens de 8 bits) os limiares variaram de 100 até 130. No caso da Figura 77 o valor limiar definido foi 120.



FIGURA 77 - VISUALIZAÇÃO SUPERFÍCIE TOMOGRAFIA 3D DO ISOLADOR TIPO ROLDANA A PARTIR DAS TOMOGRAFIAS OBTIDAS, UTILIZANDO O ALGORITMO DE *MARCHING CUBES*. FONTE: O AUTOR.

A Figura 78 mostra a tomografia tridimensional do volume reconstruído por *Ray Casting* de um isolador tipo pino. No LACVIS o *Ray Casting* pode ser utilizado como método auxiliar de visualização para inspecionar a estrutura interna do componente.




FIGURA 78 - TOMOGRAFIA TRIDIMENSIONAL DO VOLUME RECONSTRUÍDO POR RAY CASTING DE ISOLADOR TIPO PINO. FONTE: O AUTOR.

A Figura 79 mostra a malha poligonal da tomografia tridimensional de um isolador tipo pino. Pode-se ver uma bolha interna na parte superior do isolador (seta preta).




FIGURA 79 - DETALHE DA MALHA POLIGONAL RECONSTRUÍDA POR MARCHING CUBES DE ISOLADOR TIPO PINO. PODE-SE VER UMA BOLHA INTERNA NA PARTE SUPERIOR DO ISOLADOR. FONTE: O AUTOR.

A Figura 80 mostra a tomografia tridimensional (observando-se a malha poligonal) para um isolador apresentando uma bolha interna (seta preta). Na Figura 81a pode-se ver a radiografia digital da parte superior desse isolador, utilizando o detector digital plano e a fonte microfoco. Pode-se notar a presença de um vazio interno no isolador. Este isolador estava sendo utilizado e apresentou problema (ruptura dielétrica). A Figura 81b mostra a reconstrução tridimensional apenas da região do vazio e o caminho de ruptura dielétrica atravessando o vazio. Um filtro 3D Gaussiano foi aplicado nesta imagem com o objetivo de suavizar a superfície.




FIGURA 80 - MALHA POLIGONAL RECONSTRUÍDA POR *MARCHING CUBES* DE ISOLADOR TIPO PINO. PODE-SE VER UMA BOLHA INTERNA NA PARTE SUPERIOR DO ISOLADOR. FONTE: O AUTOR.



FIGURA 81 - (A) RADIOGRAFIA DIGITAL COM UTILIZAÇÃO DE DETECTOR DIGITAL PLANO DE RAIOS X DA AMOSTRA DA FIGURA 80 ONDE FOI ADQUIRIDA APENAS PARTE SUPERIOR DO ISOLADOR TIPO PINO. HÁ PRESENÇA DE UMA BOLHA E CAMINHO DE DESCARGA ELÉTRICA (INDICADA PELA SETA PRETA). (B) RECONSTRUÇÃO TRIDIMENSIONAL DA REGIÃO DA BOLHA MOSTRADA NA TOMOGRAFIA 3D DA FIGURA 80 E NA RADIOGRAFIA DE (A) EM DETALHE. A IMAGEM PERMITE VER O CAMINHO DE RUPTURA DIELÉTRICA ATRAVESSANDO O VAZIO (SETA BRANCA). FONTE: O AUTOR.

5.3 RECONHECIMENTO AUTOMÁTICO DE DEFEITOS EM TOMOGRAFIA INDUSTRIAL 3D

Nesta seção serão apresentados os resultados para a metodologia utilizada no reconhecimento automático de estruturas regulares (ER) e defeitos (D) nas tomografias tridimensionais do estudo de caso isoladores poliméricos. Os resultados mostrados nesta tese basearam-se em características tridimensionais.

Na Tabela 7 estão mostrados os resultados obtidos para os valores dos coeficientes de correlação entre as características dos objetos reconstruídos na TC 3D dos isoladores. Em teoria da probabilidade e estatística, a correlação, também chamada de coeficiente de correlação linear, indica o módulo e direção do relacionamento linear entre duas variáveis aleatórias. No uso estatístico geral, o termo correlação refere-se à medida da relação entre duas variáveis, embora correlação não implique em causalidade. Existem diversos coeficientes relatados na literatura. O mais conhecido é o coeficiente de correlação de Pearson, o qual é obtido dividindo a covariância de duas variáveis pelo produto de seus desvios padrões.

A Tabela 7 é importante por indicar as características mais relevantes no processo de reconhecimento de padrões. A coluna “classes” na tabela contém o valor do coeficiente de correlação entre as classes ER e D para cada característica. Observando a coluna classes verifica-se que existe significativa correlação entre as

características extraídas e as classes de padrões de ER e D pois, para um intervalo de confiança de 95%, a maioria das características está acima do valor limite de referência para as classes que é igual $\frac{2}{\sqrt{N}} = 0,283$ para $N = 50$ amostras. Apenas a característica F1 apresentou o menor valor de correlação entre todas as outras. A característica F9 resultaram na maior relevância entre todas na discriminação dos padrões.

TABELA 7 - COFICIENTES DE CORRELAÇÃO LINEAR ENTRE AS CARACTERÍSTICAS E CLASSES DE PADRÕES. FONTE: O AUTOR.

	F1	F2	F3	F4	F5	F6	F7	F8	F9	Classes
F1	1	0,420078	0,144255	0,466428	0,501502	-0,3036	-0,04389	-0,0025	0,025417	-0,005
F2	0,420078	1	0,878609	0,767055	0,759058	-0,98277	-0,11911	-0,09796	0,118519	-0,297
F3	0,144255	0,878609	1	0,405657	0,382746	-0,94243	-0,12531	-0,10537	0,125944	-0,301
F4	0,466428	0,767055	0,405657	1	0,995495	-0,68259	-0,12426	-0,11173	0,128826	0,315
F5	0,501502	0,759058	0,382746	0,995495	1	-0,6674	-0,12658	-0,11553	0,132161	0,247
F6	-0,3036	-0,98277	-0,94243	-0,68259	-0,6674	1	0,139417	0,119368	-0,14129	0,200
F7	-0,04389	-0,11911	-0,12531	-0,12426	-0,12658	0,139417	1	0,67858	-0,91688	0,561
F8	-0,0025	-0,09796	-0,10537	-0,11173	-0,11553	0,119368	0,67858	1	-0,91538	0,506
F9	0,025417	0,118519	0,125944	0,128826	0,132161	-0,14129	-0,91688	-0,91538	1	-0,589

5.3.1 AGRUPAMENTO DAS CLASSES

A Figura 82 mostra a distribuição das classes num espaço bidimensional formado pelas duas características de maior coeficiente de correlação linear: F7 e F9. O resultado mostrou que as duas classes apresentaram boa separação nesse espaço dimensional.




FIGURA 82 - SEPARAÇÃO DOS PADRÕES EM DUAS DIMENSÕES CONSIDERANDO AS CARACTERÍSTICAS F_7 X F_9 . FONTE: O AUTOR.

Na Figura 82, por exemplo, um classificador linear simples permite acerto de 100% das indicações de defeito, com alguns erros de falso positivo. Entretanto, deve-se destacar que nessa hipótese não estão sendo consideradas outras seis características relevantes, o que certamente aumenta o índice de acerto.

As Figura 83, 84 e 85 mostram os resultados obtidos no treinamento da rede neural SOM (*Self Organizing Map*) utilizando o MATLAB para os dados da tomografia 3D. Das 50 amostras inspecionadas, 70% foram utilizadas para treinamento da rede, 15% para testes e 15% para validação.

É mostrado na Figura 83 qual é a distância (em termos de distância Euclidiana) que cada classe de neurônio está do seu vizinho (D ou ER). Conexões de regiões de mesma classe indicam áreas altamente conectadas do espaço de entrada. Assim, as conexões indicadas por regiões escuras indicam classes de regiões do espaço de características que estão distantes. Pode-se ver que existe uma separação entre a região clara e a região escura (que determina a distância entre os neurônios), implicando o agrupamento de duas classes distintas. Esta é outra maneira de visualizar as separações de classes como mostrado na Figura 82.




FIGURA 83 - MAPA DISTÂNCIA VIZINHOS SOM 10 X 10 NODOS. AGRUPAMENTO PARA SEPARAÇÃO DAS CLASSES DEFEITO (D) OU ESTRUTURA REGULAR (ER). FONTE: O AUTOR.

A Figura 84 mostra os planos de pesos para cada uma das nove características. Eles são visualizações dos pesos que conectam cada entrada a cada um dos 100 neurônios num mapa hexagonal de (10 x 10) nodos. No mapa da Figura 84, as classes ER e D, não são indicadas à rede neural. As distâncias entre os neurônios são representadas pela cor. Quanto mais escuro, mais distantes estão os neurônios. Pode-se ver nesta figura o que já foi citado (Tabela 4). A característica F1 é muito pouco correlacionada com as duas classes em questão, não formando o agrupamento adequado. As características F7, F8 e F9, são proximamente iguais na separação das classes.

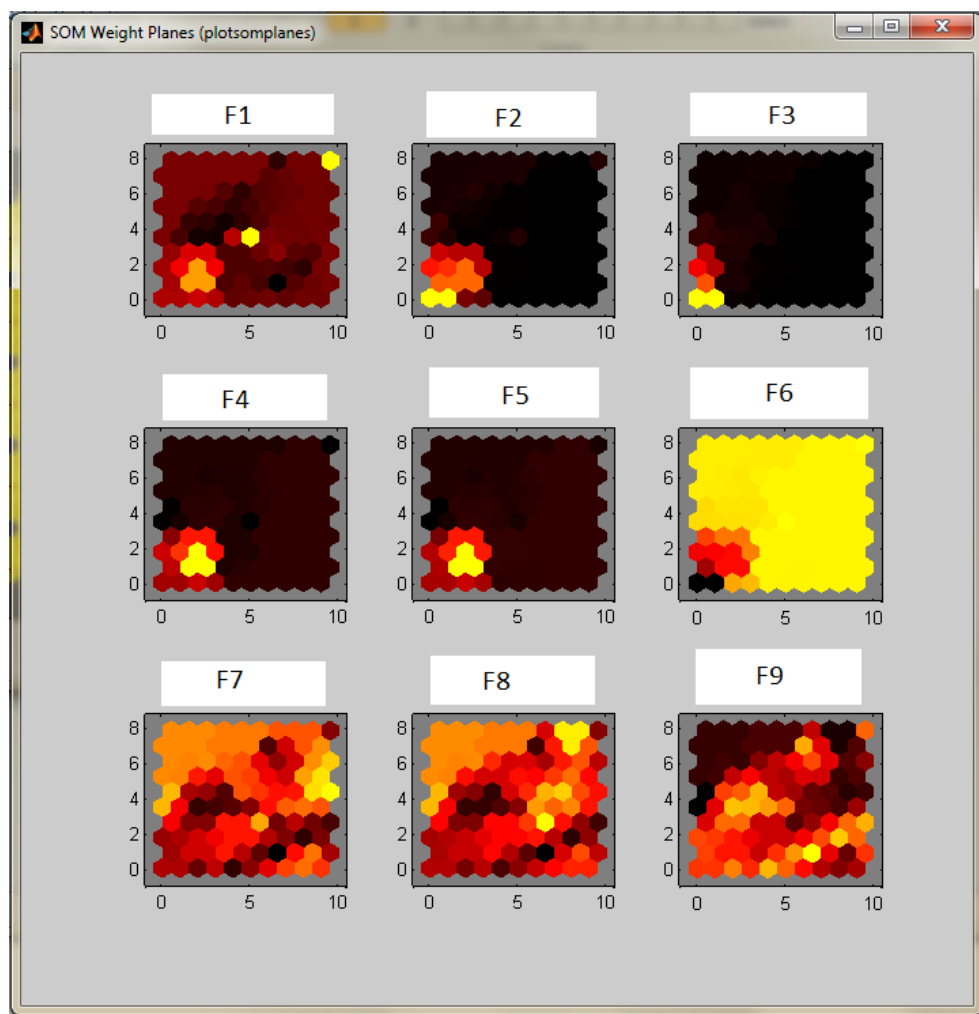


FIGURA 84 - MAPA DE AGRUPAMENTO PARA CADA CARACTERÍSTICA COM 100 NEURÔNIOS. AO TODO SÃO NOVE CARACTERÍSTICAS (NO MAPA, CARACTERÍSTICAS DE F1 ATÉ F9). FONTE: O AUTOR.

A Tabela 8 apresenta a correção entre as características. Essa tabela foi obtida pelo p-valor ($p < 0,05$, ou seja, correlação significativa). O p-valor é utilizado para sintetizar o resultado de um teste de hipóteses. O p-valor é definido como a probabilidade de se obter uma estatística de teste igual ou mais extrema quanto àquela observada em uma amostra, assumindo verdadeira a hipótese nula.

TABELA 8 - CORRELAÇÃO SIGNIFICATIVA ENTRE AS CARACTERÍSTICAS POR CÁLCULO DE P-VALOR ($P < 0,05$). FONTE: O AUTOR.

F	F
2	1
4	1
5	1
6	1
1	2
3	2
4	2
5	2
6	2
2	3
4	3
5	3
6	3
1	4
2	4
3	4
5	4
6	4
1	5
2	5
3	5
4	5
6	5
1	6
2	6
3	6
4	6
5	6
8	7
9	7
7	8
9	8
7	9
8	9

F1 é correlacionada significativamente por F2, F4, F5 e F6. F2 é correlacionada significativamente por F1, F3, F5 e F6. Pode-se ver também, na Tabela 8, que F7, F8 e F9 são altamente correlacionadas.

Na Figura 85 estão apresentadas as curvas do Erro Médio Quadrático entre o conjunto de dados de entrada e saída da rede neural. A curva em cor vermelha

ilustra o conjunto de dados de testes. A curva em cor azul os dados de treinamento e a curva em cor verde o conjunto de dados de validação. A rede convergiu em 19 épocas (iterações).




FIGURA 85 - CURVA DE DESEMPENHO DA REDE NEURAL COM 20 NEURÔNIOS NA SUBCAMADA. FONTE: O AUTOR.

A Tabela 9 mostra o resumo dos resultados de desempenho da rede neural com o cálculo do Erro Médio Quadrático.

TABELA 9 - ERRO MÉDIO QUADRÁTICO DA REDE NEURAL SOM. FONTE: O AUTOR.

Erro Médio Quadrático-Rede Neural		
Treinamento	$1,45297 \times 10^{-1}$	70% dos dados
Validação	$1,24977 \times 10^{-1}$	15 % dos dados
Teste	$1,88540 \times 10^{-1}$	15 % dos dados

5.3.2 CLASSIFICAÇÃO POR REDE NEURAL UTILIZANDO RETROPROPAGAÇÃO DE ERRO

Para implementar o classificador, recorreu-se a uma rede neural de dupla camada com treinamento por retropropagação do erro. A Tabela 10 apresenta os resultados de estudo de variação do número de neurônios na segunda camada do classificador não linear. O treinamento da rede foi parado em 3000 épocas por estabilidade do erro médio quadrático ou por esse ter atingido o critério de parada que foi de 0,001. Utilizou-se momento igual a 0,9 e taxa de aprendizagem de 0,1 com neurônios do tipo tangente hiperbólica. Foi utilizado apenas um neurônio na saída, visto ser suficiente para separar um caso de duas classes de padrões. Para testar a generalização do classificador, foram sorteados conjuntos de teste com 30% de amostras do conjunto original de dados. Destaca-se, desta forma, que os conjuntos de teste foram compostos por 15 amostras. A classe ER, contém 27 amostras e a classe D, 23 amostras. O sorteio foi aleatório mantendo-se essa proporção entre ER e D.

TABELA 10 - VARIAÇÃO DO NÚMERO DE NEURÔNIOS NA CAMADA INTERMEDIÁRIA. FONTE: O AUTOR.

Número de neurônios	Treinamento (%)	Teste (%)
1	91,43	93,4
2	97,15	86,7
3	94,3	86,7
4	100	66,7
5	100	66,7
6	100	73,4
7	100	66,7
8	97,2	80
9	100	66,7
10	100	66,7

Pelos resultados observa-se que, quanto maior o número de neurônios na camada intermediária, maior foi o acerto de classificação com os dados de treinamento. Com um neurônio apenas, obteve-se mais de 91% de acerto para treinamento e mais de 93% para teste. Esta é uma situação atípica em se tratando de rede neural, pois na maioria das vezes houve menor acerto com os conjuntos de teste, devido ao processo de reconhecimento de padrões. Entretanto, isso pode acontecer quando o treinamento se encerra prematuramente e os dados de teste,

involuntariamente, apresentam um acerto maior. Numa situação mais realista, com dois e três neurônios, têm-se acertos de 97,15% e 94,3%, respectivamente. Nesse caso, os conjuntos de teste apresentaram índices de 87,7%, isto é, 13 acertos em 15. Aumentando-se o número de neurônios, verificou-se que o treinamento chegou a 100%, enquanto os testes resultaram para faixas entre 66 e 80%. Isso é lógico em treinamento de rede neural, pois há provável supertreinamento dos seus parâmetros (sinapses e bias ou tendência), o que provoca um erro maior com as amostras de teste. Conclui-se que, com dois ou três neurônios, obteve-se a melhor situação de generalização do classificador não linear.

Na Tabela 11 estão mostrados os resultados obtidos para acurácia estimada para classificador não linear por seleção randômica sem reposição (número de Verdadeiros Positivos em %). A quarta e quinta colunas da tabela referem-se ao número de dados de cada classe contida no correspondente grupo de teste. A média foi aproximadamente cinco dados de entrada de cada classe em cada grupo, isto é, não houve significativa desproporção entre o número de dados de entrada de cada classe que poderiam afetar os dados de treinamento e teste dos classificadores. As colunas de treinamento e teste contêm não somente as porcentagens de sucesso, mas, também, o número de dados corretamente classificados.

TABELA 11 - ACURÁCIA ESTIMADA PARA CLASSIFICADOR NÃO LINEAR POR SELEÇÃO ALEATÓRIA SEM REPOSIÇÃO (NÚMERO DE VERDADEIROS POSITIVOS EM %). FONTE: O AUTOR.

Dados de Entrada	Treinamento (%)	Teste (%)	Estrutura Regular	Defeito	Falso Negativo (%)	Falso Positivo (%)
1	37/92,5	6/60,0	7	3	0	42,85
2	36/90,0	7/70,0	5	5	0	42,85
3	36/90,0	7/70,0	5	5	0	42,85
4	36/90,0	8/80,0	4	6	0	50,00
5	37/92,5	7/70,0	6	4	0	42,50
Média (%)	91,0	70,0	≈ 5		0	46,25
Desvio Padrão (%)	1.25	7,0			0	5%

A Figura 86 mostra a curva ROC da interpolação dos pontos dos dados verdadeiros positivos (TP), 1-FN e falsos positivos (FN) da Tabela 11. A área sob a curva, calculada por simples integração dos pontos interpolados pela curva, representa a eficiência do sistema usado para detecção dos defeitos reais nas imagens adquiridas (probabilidade de detecção - PoD). Nesse caso, o valor

encontrado para a área foi de 78,6%, o qual pode ser considerado um índice ótimo da eficiência e confiança do sistema. Maior que 70,0% do valor da acurácia estimada da Tabela 11, terceira coluna. Pode-se enfatizar que o número de verdadeiros positivos foi de 100% para todos os grupos de dados. Apesar da falta de amostras para a formação de classificadores, este resultado pode ser considerado muito satisfatório.




FIGURA 86 - CURVA ROC RESULTANTE DOS GRUPOS SELECIONADOS ALEATORIAMENTE SEM REPOSIÇÃO DE DADOS (TABELA 11). FONTE: O AUTOR.

De acordo com os dados das Tabela 11 e Tabela 12, os resultados de acurácia de classificação para a implementação de classificadores foi de 70,0% e no caso de seleção aleatória sem reposição de dados de 65,8% no caso de seleção aleatória com reposição utilizando a técnica de *bootstrap* (Tabela 12). Embora esses resultados se mostrem inferiores aos apresentados na Tabela 11, eles foram mais realísticos uma vez que eles correspondem ao valor estimado baseado em cinco seleções aleatórias. A fim de treinar e testar esses classificadores, os mesmos parâmetros de formação mencionados anteriormente foram utilizados, ou seja, momento, taxa de aprendizagem, o número de épocas e critério de parada, entre outros. Geralmente, na classificação de padrões, os resultados dos testes foram inferiores em comparação com os resultados dos treinamentos realizados por uma margem de 10 a 15%. No entanto, nesta situação, a influência de outros parâmetros foram relevantes, por causa da baixa quantidade de dados disponíveis, ou seja, 40

amostras para treinamento e 10 amostras para teste, no caso de seleção aleatória sem reposição. Com a técnica *bootstrap*, a variação normal ficou entre 25 e 35% dos dados de ensaio e, para os dados de treinamento foram mantidas, as 50 amostras. Os resultados obtidos mostraram que foi possível detectar automaticamente falhas em imagens de TC industrial 3D em amostras de isoladores poliméricos, o que indica o potencial de aplicações com inspeções de defeitos semelhantes em outros tipos de componentes. Além disso, as comparações feitas com outros trabalhos mostram que a abordagem deste trabalho é inovadora e promissora. Podem-se obter ainda melhores resultados no processo de classificação mediante o uso de uma maior quantidade de amostras. Também pode-se analisar o potencial de obtenção de classificações com mais precisão mediante o estudo de outros tipos de características. Assim, evidencia-se o potencial da metodologia apresentada neste trabalho no diagnóstico automático não destrutivo de defeitos em equipamentos.

TABELA 12 - ACURÁCIA ESTIMADA DO CLASSIFICADOR NÃO LINEAR POR TÉCNICA DE *BOOTSTRAP* (NÚMERO DE VERDADEIROS POSITIVO). FONTE: O AUTOR.

Dados de Entrada	Dados de Treinamento (%)	Dados de Teste (%)
1	47/94,0	10/71,4
2	45/90,0	14/66,7
3	48/96,0	11/52,4
4	45/90,0	14/66,7
5	42/84,0	10/71,4
Acurácia estimada	65,80%	

6 CONCLUSÕES

Os resultados indicam que a metodologia desenvolvida nesta tese para o reconhecimento automático de objetos em tomografia industrial 3D pode ser utilizada em qualquer área, inclusive em imagens médicas, pois ela mostra-se bastante “plástica” ou “adaptável” a distinção de classes num problema de reconhecimento de padrões 3D.

A ferramenta computacional desenvolvida, denominada LACVis, que tem por objetivo a visualização das tomografias tridimensionais industriais e a detecção de defeitos em ambiente 3D foi aplicada ao estudo de caso de defeitos em isoladores poliméricos tipo pino e roldana. No entanto, ela está documentada e permite alterações e implementações futuras para ampliar a aplicação a outros tipos de componentes do setor elétrico e industrial. O aplicativo desenvolvido é um protótipo, mas a tecnologia pode ser transferida a um desenvolvedor de *software* caso tenha interesse. A visualização 3D de dados volumétricos é uma ferramenta valiosa para a inspeção de defeitos em isoladores poliméricos. Ela também permitiu a visualização do caminho formado para descarga elétrica em isoladores.

Em relação à segmentação e levantamento de característica 3D, o trabalho mostrou vantagens da segmentação tridimensional sobre a técnica de segmentação e levantamento de atributos convencional, em imagens 2D, ou seja, robustez e redução de tempo. Aliada ao resultado obtido na tese de que, no domínio 3D, apenas algumas características geométricas são necessárias para a classificação bem-sucedida pela rede neural, o que em 2D, geralmente é necessário obter características topológicas. Além disso, a metodologia 3D em END é mais intuitiva e simples de operar do que o método 2D convencional. Para segmentação de objetos 3D, o *Marching Cubes* foi escolhido por ser um dos algoritmos mais robustos e eficientes de extração de superfícies, e pelos resultados satisfatórios alcançados quando da sua utilização para reconstruir objetos em tomografia 3D.

A metodologia utilizada para o reconhecimento de padrões tridimensionais apresentou resultados satisfatórios na identificação de defeitos em isoladores. Considerando-se o que foi citado no Capítulo 2, a abordagem de detecção dos defeitos diretamente no espaço tomográfico tridimensional do componente foi inovadora. Os testes com a rede neural mostraram que é possível chegar a boas

taxas de classificação empregando nove características extraídas das imagens de tomografia computadorizada em 3D. Mesmo com número de amostras pequenos, no estudo de caso utilizado, foi possível tirar conclusões definitivas sobre o desempenho com dados de teste.

A rede SOM mostrou-se ferramenta importante no estudo da separação das classes. A visualização dos pesos fornecida por ela permitiu verificar os agrupamentos das classes. Por ser de fácil implementação, pode ser utilizada em um sistema para reconhecimento de defeitos 3D aliada a metodologia apresentada aqui.

Os resultados apresentados nesta tese foram validados estatisticamente, pelas curvas de sensibilidade e cálculos de hipóteses. A partir do estudo de correlação obtido, do cálculo do p -valor e da distribuição de agrupamentos pela rede SOM, verificou-se que a característica F1 (que descreve a forma do objeto em proximidade a uma esfera) é dispensável para definição de um sistema de classificação dos defeitos nos isoladores. O cálculo do p -valor mostrou também que as características F7, F8 e F9 (volumes projetados em x, y e z) são altamente correlacionadas, o que implica no desenvolvimento de um sistema de classificação, na redução da utilização de apenas uma delas.

Esta tese mostrou que é possível detectar automaticamente objetos no espaço 3D em imagens de TC industrial aplicada ao estudo de caso de defeitos em isoladores, o que indica o potencial de aplicações com inspeções de defeitos semelhantes em outros tipos de componentes. Para verificação de não-conformidade de um lote de componentes, a metodologia desenvolvida aqui pode ser utilizada como ferramenta de apoio a norma brasileira NBR 5426/85 que dá as diretrizes para os “Planos de Amostragem e Procedimentos na Inspeção por Atributos”.

7 PUBLICAÇÕES

Em termos da divulgação tecnológica, o desenvolvimento deste trabalho originou artigos publicados em revista indexada de circulação internacional. Três artigos foram publicados na revista inglesa de ensaios não destrutivos *Insight* (Northampton), *qualis* B2. Um artigo também foi submetido a um congresso internacional do IEEE denominado Compumag em 2009. Abaixo segue lista das publicações:

- Godoi, W. C.; de Geus, K.; da Silva, R. R.; Swinka-Filho, V., “*Automated flaw detection in x-ray tomography of polymer insulators*”. *Insight* (Northampton), v. 52, p. 533-539, 2010.
- Mendes, R.; Portella, K. F.; Godoi, W. C.; Galvão, J. C. A. ; Joukoski, A.; Martins, P.; Swinka-Filho, V.; de Geus, K., “*Determination of crushed stone volume in concrete cores from hydroelectric power plant dams by three-dimensional tomography*” *Insight* (Northampton), v. 51, p. 654-659, 2009.
- Godoi, W. C.; Geus, Klaus de; da Silva, R. R.; Swinka-Filho, V. “*Detecção Automática de vazios em Isoladores Poliméricos por Tomografia Industrial 3D*”, *Espaço Energia*, v.11, p. 29-34, 2009.
- Godoi, W C; Geus, K de; Swinka-Filho, V; da Silva, R. R. “*Volume and surface measurements of flaws in polymeric insulators using X-ray computed tomography*” *Insight* (Northampton), v. 50, p. 554-559, 2008.
- Mendes, R.; Portella, K F; Galvão, J. C. A.; Godoi, W C; Martins, P; Swinka-Filho,V. “*Reconhecimento de Patologias de Concreto Utilizando a Técnica de Tomografia Industrial de Raio X (TRX)*” In: 51º Congresso Brasileiro do Concreto - CBC2009, 2009, Curitiba. *Anais do 51º Congresso Brasileiro do Concreto - CBC2009*, p. 172-172, 2009.
- Fagundes, R. C.; Godoi, W. C.; Vasco, M. A. A.; Lazzaretti, A. E.; Swinka-Filho,V.; Geus, K de . “*Simulation of Electric Field Distribution in Polymeric Insulators*” In: COMPUMAG, 2009, Florianópolis. *Proceedings of the 17th Conference on the Computation of Eletromagnetic Fields IEEE*, p. 875-876, 2009.

- Godoi, W. C.; Finta, E.; Knaut, D.; Nepomuceno, Z. T.; Abreu, C. C. A; Swinka-Filho, V., “Radiografia e Tomografia Industriais: Estudos em Amostras de Concreto”, PART I e II, Revista do CONTER, Brasil, 2011.

8 SUGESTÕES PARA TRABALHOS FUTUROS

Como sugestão de trabalhos futuros, citam-se alguns pontos de contexto com esta tese de doutorado:

- desenvolver algoritmos de registro de quatro imagens para a nova mesa tomográfica, o que implicará na capacidade de realizar tomografias e radiografias de objetos inferiores a 24 cm x 22 cm;
- ampliar o desempenho computacional, implementar em processamento paralelo, via GPU (*Graphical Process Unit*) dos algoritmos para reconstrução 2D e 3D de tomografias;
- implementar o sistema desenvolvido aqui em linha de produção de componentes e realizar estudo comparativo quantitativamente dos resultados de desempenho de reconhecimento de padrões a partir de fatias 2D com o reconhecimento direto 3D;
- utilizar o algoritmo de *Ray Casting* para fornecer características topológicas para classificação 3D em imagens médicas ou industriais, como por exemplo, parâmetros para densidade e opacidade de materiais.

REFERÊNCIAS

1. ABENDI. Associação Brasileira de Ensaios Não Destrutivos e Inspeção. Disponível em: <<http://www.abende.org.br>>. Acesso em: 07 Fevereiro 2011.
2. ANDREAS, P., BALTZER, T., RENZ, D. M., KULLNIG, P. E., GAJDA, M., CAMARA, O., KAISER, W. A., “Application of Computer-aided Diagnosis (CAD) in MR-Mammography (MRM): Do We Really Need Whole Lesion Time Curve Distribution Analysis?”, *Academic Radiology*, v. 16, n. 4, April, 2009.
3. WOLF, M., KRISHNAN, A., SAGANICOFF, M., BI, J., DUNDAR, M., FUNG, G., STOECKEL, J., PERIASWAMY, S., SHEN, H., HERZOG, P., “CAD performance analysis for pulmonary nodule detection on thin-slice MDCT scans”, **International Congress Series**, v. 1281, p. 1104-1108, 2005.
4. LI, Q., “Recent progress in computer-aided diagnosis of lung nodules on thin-section CT”, **Computerized Medical Imaging and Graphics** , p. 248-257, 2007.
5. WIEMKER, R., ROGALLA, P., BLAFFERT, T., SIFRI, D., HAY, O., SRINIVAS, Y., TRUYEN, R., “Computer-aided detection (CAD) and volumetry of pulmonary nodules on high-resolution CT data”, **Medica Mundi**, v. 3, p.37-44, 2003.
6. ISGUM, I.; GINNEKEN, B. V.; OLREE, M., “Automatic Detection of Calcifications in the Aorta from CT Scans of the Abdomen”, **Academic Radiology**, v. 11, 2004.
7. ZHOU, Z.; LIU, J.; LE, A. H., “CAD–PACS integration tool kit based on DICOM secondary capture, structured report and IHE workflow profiles”, **Computerized Medical Imaging and Graphics**, p. 346-352, 2007.

8. HSU, C.-Y.; LIU, C.-Y.; CHEN, C.-M., "Automatic segmentation of liver PET images", **Computerized Medical Imaging and Graphics**, p. 601-610, 2008.
9. AZEVEDO-MARQUES, P. M. D., "Diagnóstico Auxiliado por Computador na Radiologia", **Radiologia Brasileira**, v. 5, n. 34, p. 285-293, 2001.
10. PÁDUA, G. X. de; SILVA, R. R. da; MERY, D.; REBELLO, J. M. A., CALOBA, L., "Detection and Classification of weld Discontinuities in Radiographic Images - Part III: Unsupervised Learning - Phenomenological Analysis", **Materials Evaluation**, p. 145-149, 2008.
11. MERY, D., "Automated Detection of Welding Discontinuities without Segmentation", **Materials Evaluation**, p. 657-663, 2011.
12. CARRASCO, M.; MERY, D., "Automatic Multiple View Inspection using Geometrical Tracking and Feature Analysis in Aluminum Wheels", **Machine Vision and Applications**, v. 22, p. 157-170, 2010.
13. ABATE, A. F., NAPPI, M., RICCIO, D., SABATINO, G., "2D and 3D face recognition: A survey", **Pattern Recognition Letters**, v. 28, p. 1885–1906, 2007.
14. LLONCHA, R. S., KOKIOPOULOU, E., TOSIC, I., FROSSARD, P., "3D face recognition with sparse spherical representations", **Pattern Recognition** , v. 43, p. 824 -- 834, 2010.
15. XU, C., LI, S., TAN, T., QUAN, L., "Automatic 3D face recognition from depth and intensity Gabor features", **Pattern Recognition**, v. 42, p. 1895 -1905, 2009.
16. CHEN, H.; BHANU, B., "3D free-form object recognition in range images using

- local surface patches”, **Pattern Recognition Letters**, v. 28, p. 1252–1262, 2007.
17. HAM, Y. K.; PARK, R.H., “ 3D object recognition in range images using hidden markov models and neural networks”, **Pattern Recognition** , v. 32, p. 729-742, 1999.
 18. KITA, Y., TOHNO, E., HIGHNAM, R. P., BRADY, M., “A CAD System for the 3D Location of Lesions in mammograms”, **Medical Image Analysis**, v. 6, p. 267-273, 2002.
 19. STAAL, J.; GINNEKEN, V.; VIERGEVER, A., “Automatic rib segmentation and labeling in computed tomography scans using a general framework for detection, recognition and segmentation of objects in volumetric data”, **Medical Image Analysis**, p. 35-46, 2007.
 20. BONA, D. S., et al, “Brain Volumes Characterization Using Hierarchical Neural Networks”, **Artificial Intelligence in Medicine**, v. 28, p. 307-322, 2003.
 21. HAM, Y. K.; PARK, R. H., “3D Object Recognition in Range Images Using Hidden Markov Models and Neural Networks”, **Pattern Recognition**, v. 32, p. 729–742, 1999.
 22. SON, H.; KIM, C., “3D structural component recognition and modeling method using color and 3D data for construction progress monitoring”, **Automation in Construction**, v. 19, p. 844–854, 2010.
 23. GOLOSIO, B.; BRUNETTI, A.; AMENDOLIA, S. R., “A Novel Morphological Approach to Volume Extraction in 3D Tomography”, **Computer Physics Communications**, v. 141, p. 217–224, 2001.

24. GODOI, W. C. **Detecção de Defeitos em Isoladores Poliméricos por Radiografia Digital**, Dissertação de Mestrado, Universidade Federal do Paraná. Curitiba. 2005.
25. MUNSHI, P. (Ed.), **“Computerized Tomography for Scientists and Engineers”**, Kanpur: Anamaya Publishers, 2007.
26. MCCORMICK, B. H.; DEFANTI, T. A.; BROWN, M. D., **“Visualization in Scientific Computing”**, 1987.
27. BUZUG, T. M., **“Computer Tomography – From Photon Statistics to Modern Cone-Beam CT”**, Springer, Berlin, 2008.
28. EISBERG, R.; RESNICK, R., **“Física Quântica - Átomos, Moléculas, Sólidos, Núcleos e Partículas”**, 4a. ed., Campus, Rio de Janeiro, 1988.
29. CORREA, S. C., **“Otimização da Dose e da Imagem Radiográfica Digital de Tórax Usando Modelagem Computacional”**, Tese de Doutorado, Universidade Federal do Rio de Janeiro, Rio de Janeiro, 2009.
30. GONZALEZ, R. C.; WOODS, R. E., **“Processamento de Imagens Digitais”**, Edgard Blucher, 2000.
31. PIEKARZ, A. H., **“Determinação do Volume de Vazios em Isoladores Poliméricos por Tomografia Digital de Raios X”**, Dissertação de Mestrado, Universidade Federal do Paraná, Curitiba, 2006.

32. RIBEIRO-JÚNIOR, S., “**Análise da Ruptura Dielétrica em Materiais Isolantes Elétricos de Cabos Isolados XLPE e EPR por Tomografia 2D e 3D**”, **Dissertação de Mestrado**, Universidade Tecnológica Federal do Paraná, Curitiba, 2008.
33. BLINN, J. F., “What Is a Pixel?”, **IEEE Computer Graphics and Applications**, p. 82-87, 2005.
34. KAK, A. C.; SLANEY, M., “**Principles of Computerized Tomographic Imaging**”, New York: Society for Industrial and Applied Mathematics, 2001.
35. NÓBREGA, A. I. D., “**Manual de Tomografia Computadorizada**”, ed. Atheneu, 2005.
36. HERMAN, G. T., “**Image Reconstruction from Projections**”, Academic Press, 1980.
37. SANTOS, J.; LONGORIA, J. C.; PALACIOS, J. C., “Detection of Flaws in Construction Columns Using 3D Reconsrtruction and Manipulation”, **Linear Algebra and its Applications**, p. 195–204, 2001.
38. LU, S.; LANDIS, E. N.; KEANE, D. T., “X-ray microtomographic studies of pore structure and permeability in Portland cement concrete”, **Materials and Structures**, v. 39, p. 611–620, 2006.
39. SALVO, L.; CLOETEN, P.; MAIRE, E. et al. X-ray micro-tomography an attractive characterisation technique in materials science. **Nuclear Instruments and Methods in Physics Research B**, v. 200, p. 273–286, 2003.

40. LUGAR, R. D., MORTON, E. J., JENNESON, P. M., KEY, M. J., "X-ray Tomographic Imaging in Industrial Process Control", **Radiation Physics and Chemistry**, v. 61, p. 785 - 787, 2001.
41. HIRAKIMOTO, A. et al, "Progress of Microfocus X-ray Systems for Fluoroscopic and Computed Tomography", **Spectrochimica Acta Part B**, v. 59, p. 1101–1106, 2004.
42. CHAUNIER, L.; VALLE, G. D.; LOURDIN, D. "Relationships Between Texture, Mechanical Properties and Structure of Cornflakes",. **Food Research International**, v. 40, p. 493-503, 2007.
43. BRUNETTI, A. et al, "Visualization of Monomer and Polymer Inside Porous Stones by Using X-ray Tomography", **Nuclear Instruments and Methods in Physics Research B**, v. 222, p. 235–241, 2004.
44. BORD, S. et al, "An X-ray Tomography Facility for I.C. Industry at TMicroelectronics Grenoble", **Microelectronic Engineering**, v. 2, 2002.
45. WITHERS, P. J., "X-ray nanotomography", **Materials Today**, v. 10, p. 26-34, 2007.
46. XRADIA, "XRadia Insight in 3D", **XRadia Insight in 3D**. Disponível em: <<http://www.xradia.com/>>. Acesso em: 27 março 2012.
47. DARLING, A. et al, "**Micro-CT Characterization of Fusing Extruded PCL Scaffolds**", Proceedings of Bioengineering Conference - IEEE 29th Annual, p. 166–167, 2003.

48. DUONG, H. T. T.; BURFORD, R. P., “Effect of Foam Density, Oil Viscosity, and Temperature on Oil Sorption Behavior of Polyurethane”, **Journal of Applied Polymer Science**, v. 99, p. 360–367, 2006.
49. SKALNY, J.; MINDESS, S. (Eds.), “**Material Science of Concrete**”, The American Ceramic Society, 1998.
50. QUOIRIN, N. S. R., “**Diagnóstico de Defeitos em Madeira por Tomografia de Raios-X**”, **Dissertação de Mestrado**, Universidade Federal do Paraná, Curitiba, 2004.
51. MENDES, R., “**A Tomografia Computadorizada de Raios X Como Metodo Não Destrutivo de Análise Volumétrica de Concreto: Estudo de caso em Testemunho de Concreto da Usina Hidroelétrica Mourão**”, **Dissertação de Mestrado**, Universidade Federal do Paraná, Curitiba, 2010.
52. PAIVA, A. C.; SEIXAS, R. B.; GATTAS, M., “**Introdução à Visualização Volumétrica**”, Pontifícia Universidade Católica, Rio de Janeiro, 1999.
53. LORENSEN, W. E.; CLINE, H. E., “Marching Cubes: A high Resolution 3D Surface Construction Algorithm”, **Computer Graphics**, v. 21, p. 163–169, 1987.
54. DREBIN, R. A.; CARPENTER, L.; HANRAHAN, P. “Volume Rendering”, **Computer Graphics**, v. 22, p. 65-74, 1988.
55. SOUZA, M. A., “**Integrando Reconstrução 3D de Imagens Tomográficas e Prototipagem Rápida a Fabricação de Modelos Médicos**”, **Dissertação de Mestrado**, Centro Federal de Educação Tecnológica, Curitiba, 2002.

56. CLINE, H. E.; LORENSEN, W. E., “**System and Method for the Display of Surface Structures Contained Within the Interior Region of Solid Body**”, patent no. 4710876, 1987.
57. SCHROEDER, W.; ZARGE, J.; LORENSEN, W., “Decimation of Triangle Meshes”, **Computer Graphics**, v. 26, p. 65-70, 1992.
58. KITWARE INC. VTK, “**Visualization Toolkit**”, Disponível em: <<http://www.vtk.org>>. Acesso em: 10 Maio 2011.
59. FOLEY, J. D. et al, “**Computer Graphics - Principles and Practice**. [S.l.]: Addison-Wesley, 1990.
60. COHEN, D., “Voxel Traversal Along a 3D Line”, **Graphics Gems IV**, p. 366–369, 1994.
61. ELVINS, T. T., “A Survey of Algorithms for Volume Visualization”, **Computer Graphics**, v. 26, 1992.
62. APPEL, A., “**Some Techniques for Shading Machine Renderings of Solids**”, Spring Joint Computer Conference, p. 37–45, 1968.
63. DUDA, R. O.; HART, P. E.; STORK, D. G., “**Pattern Classification**”, 2a. ed., Wiley , 2000.
64. FISHER, R. A., “The use of multiple measurements in taxonomic problems”, **Annual Eugenics**, v. 7, p. 179–188, 1936.
65. HAYKIN, S., “**Redes Neurais - Princípios e Prática**”, 2a. ed., Bookman, 2001.

66. MCCULLOCH, W.; PITTS, W., "A logical calculus of the ideas immanent in nervous activity", **Bulletin of Mathematical Biophysics**, v. 7, p. 115-133, 1943.
67. HEBB, D. O., "**The organization of behavior**", Wiley & Sons, New York, 1949.
68. ROSENBLATT, F., "The Perceptron: A Probabilistic Model for Information Storage and Organization in the Brain", **Psychological Review**, v. 65, n. 6, p. 386-408, 1958.
69. HOPFIELD, J. J., "Neural networks and physical systems with emergent collective computational abilities", **Proceedings of the National Academy of Sciences of the USA**, v. 79, p. 2554–2558, 1982.
70. RUMELHART, D. E.; L. J. "**Parallel distributed processing: Computational models of cognition and perception**", MIT, 1986.
71. LNCC, "O Algoritmo Backpropagation", Disponível em: http://www.lncc.br/labinfo/tutorial-RN/frm4_backpropagation.htm, acesso em: 28 maio de 2011.
72. KOHONEN, T., "**Self-Organizing Maps**", Springer-Verlag, New York, 1997.
73. KOHONEN, T., "The Self-Organizing Map", **Proceeding Of IEEE**, v. 78, 1990.
74. FAUSETT, L., "Fundamentals of Neural networks - Architectures, Algorithms and Applications", Prentice Hall, p. 169-175, 1994.
75. MATHWORKS, "**MATLAB - Neural Networks Toolbox Manual**", 2011.

76. CARVALHO, A. A., “**Confiabilidade de Técnicas de Ensaios Não Destrutivos na Inspeção de Dutos Utilizados na Indústria do Petróleo**”, **Tese de Doutorado**, Universidade Federal do Rio de Janeiro, Rio de Janeiro, 2006.
77. NOCKEMAN, C.; HEIDT, H. H.; THOMSEN, N., “Reliability in NDT: ROC Study of Radiographic Weld Inspections”, **NDT&E International**, v. 24, 1991.
78. SILVA, R. R. D., “**Reconhecimento de Padrões de defeitos de Soldagem em Radiografias Industriais**”, **Tese de Doutorado**, Universidade Federal do Rio de Janeiro, Rio de Janeiro, 2003.
79. FAWCETT, T., “An introduction to ROC analysis”, **Pattern Recognition Letters**, v. 8, p. 861–874, 2006.
80. DIAMANTIDIS, N. A.; KARLIS, D.; GIAKOUMAKIS, E. A., “Unsupervised Stratification of Cross-Validation for Accuracy Estimation”, **Artificial Intelligence**, v. 116, p. 1-16, 2000.
81. EFRON, B.; TIBSHIRANI, R. J., “**An Introduction to the Bootstrap**”, Chapman & Hall, New York, 1993.
82. MANRICH, S., “**Processamento de Termoplásticos: Rosca Única, Extrusão e Matrizes, Injeção e Moldes**”, ed. Artliber, 2005.
83. RODRIGUES, L. F. N.; ALMEIDA, A. D.; SILVA, M. R. D., “**NDT-25 - Isolador de Ancoragem Polimérico Classes 15 e 36,2 kV - Especificação e Padronização**”, Companhia Energética de Goiás, 2001.

84. VTK- **Visualization Toolkit**, Disponível em: <<http://www.vtk.org>>. Acesso em: 10 Fevereiro 2011.
85. ALYASSIN, A. M., LANCASTER, J. L., DOWNS, J. H., “Evaluation of new algorithms for the interactive measurement of surface area and volume”, **Medical Physics**, v. 6, 1994. ISSN 21.
86. MATHWORKS, “MATLAB - The Language Of Technical Computing”, Disponível em: <<http://www.mathworks.com/products/matlab/index.html>>. Acesso em: 26 Janeiro 2012.
87. VICENTINOS DO BRASIL. Disponível em: <<http://www.vicentinos.com.br>>. Acesso em: 25 março 2011.
88. SCHROEDER, W.; MARTIN, K.; LORENSEN, B., “**The Visualization Toolkit – An Object-Oriented Approach to 3D Graphics**”, 3rd. ed. Kitware, 2004.
89. GODOI, W. C. , GEUS, K. de; SWINKA-FILHO, V., SILVA, R. R. da, “Volume and Surface Measurements of Flaws in Polymeric Insulators Using X-ray Computed Tomography”, **Insight - Non Destructive Testing and Condition Monitoring**, v. 50, p. 554–559, 2008. ISSN 10.
90. SILVEIRA, A. J. P.; MELLO, D. R.; AGUIAR, G., “**Isoladores Poliméricos: As Experiências da Enersul - Rede de energia da Escelsea**”, Puerto Iguazú, 2009.
91. SOARES, F. A.; LOPES, H. B., “**Apostila de Tomografia Computadorizada**”, Centro Federal de Educação Tecnológica. Florianópolis, p. 12, 2000.

92. ANTUNES, A. M.; SWINKA-FILHO, V.; DE GEUS, K.; RUBIO, C. A.; MILTSZTAJN, F.; GODOI, W. C., **“Desenvolvimento de Técnica de Diagnóstico Automático por Tomografia Tridimensional de Componentes Elétricos”**, Relatório Projeto P&D, Instituto de Tecnologia para o Desenvolvimento, Curitiba, 2006.

APÊNDICE A - CÓDIGO FONTE LACVIS – SOFTWARE TOMOGRAFIA TRIDIMENSIONAL

Apresenta-se a seguir um resumo comentado do código fonte do *software* de tomografia tridimensional denominado LACVIS. Esta ferramenta foi desenvolvida na linguagem Java em interface de desenvolvimento Netbeans no sistema operacional Linux Ubuntu. Na Figura A1 está mostrada a interface para o usuário do *software*.




FIGURA A1 - INTERFACE DO LACVIS. FONTE: O AUTOR.

Apresenta-se a seguir as principais linhas do código desenvolvido.

Abaixo apresentam-se as declarações iniciais no arquivo principal “LACVISView.java”. Deve-se importar a biblioteca `vtk.jar`.

```

1 /*
2  * LACVISView.java
3  */
4
5 package lacvis;
6
7 import java.awt.Image;
8 import org.jdesktop.application.Action;
9 import org.jdesktop.application.ResourceMap;
10 import org.jdesktop.application.SingleFrameApplication;

```

```

11 import org.jdesktop.application.FrameView;
12 import org.jdesktop.application.TaskMonitor;
13 import java.awt.event.ActionEvent;
14 import java.awt.event.ActionListener;
15 import javax.swing.Timer;
16 import javax.swing.Icon;
17 import javax.swing.JDialog;
18 import javax.swing.JFrame;
19 import vtk.*;
20 import java.io.*;
21 import javax.imageio.ImageIO;
22
23
24 /**
25  * O frame principal da aplicação
26  */
27 public class LACVISView extends FrameView {
28

```

No menu principal da Figura B1, em “Arquivo” e depois “Importar Fatias” segue-se o seguinte código.

```

587 private void jMenuItem1ActionPerformed(java.awt.event.ActionEvent evt) {
588     //Mostra Frame para carregamento das fatias tomográficas e parâmetros
589     JFrame1.setTitle(".:Importar Fatias::Parâmetros.:");
590     JFrame1.setSize(640, 480);
591     JFrame1.setVisible(true);
592
593 }
596 private void jButton1ActionPerformed(java.awt.event.ActionEvent evt) {
597 // Botão (...) do Frame para importar tomografias
598 //Define o FileChooser
599 javax.swing.JFileChooser jFileChooser1 =new javax.swing.JFileChooser();
600 //Título da Caixa do FileChooser
601 jFileChooser1.setDialogTitle("Selecione uma Tomografia...");
602 //Mostra o FileChooser
603 int returnVal = jFileChooser1.showOpenDialog(JFrame1);
604 // Define o dialogo 1: Aviso de CANCEL na seleção do arquivo
605 javax.swing.JDialog jDialog1=new javax.swing.JDialog();
606 //-----
607 if (returnVal == jFileChooser1.APPROVE_OPTION) {
608     File aux = jFileChooser1.getSelectedFile();
609     File aux2 = jFileChooser1.getCurrentDirectory();
610
611     //Strings Utilizadas
612     String str1 = aux.getPath();
613     String str2 = aux.getParent();//Diretório raiz para Tomografia_...
614     String[] str02=aux.list();
615     String str3 = aux.getName();
616     String str4 = jTextField2.getText();//Fatia Inicial
617     String str5 = jTextField3.getText();//Fatia Final
618     File aux01 = jFileChooser1.getSelectedFile();
619     String Arquivo = jFileChooser1.getName(aux01); //Novo
620     String directorio= aux01.getParent(); //Novo Diretório raiz para Tomografia_...
621
622     //Coloca o caminho do arquivo na caixa de texto
623     // O nome do arquivo tem que começar com Tomografia_ (prefixo das tomografias)
624     //Se o nome do arquivo iniciar com Tomografia_ ...
625     try {

```



```

626     textField1.setText(str2 + "/Tomografia_");
627 //-----
628     Image image = ImageIO.read(aux); //lê a imagem da fatia e armazena na variavel imagem
629     //int fatiaInicial = Integer.parseInt(str4); //Converte string para int (fatia inicial)
630     //int fatiaFinal = Integer.parseInt(str5); //Converte string para int (fatia final)
631     largImage=image.getWidth(jFrame1); // Largura imagem tipo int
632     altImage=image.getHeight(jFrame1); // Altura imagem tipo int
633     String str6 = String.valueOf(largImage); // Largura imagem tipo String
634     String str7 = String.valueOf(altImage); // Altura imagem tipo String
635     //Imprime as dimesnões da imagem
636     jLabel3.setText("Dimensões Fatia: "+str6+" x "+ str7+" pixels");
637 } catch (IOException ex) {
638     System.out.println("Problema ao acessar o arquivo "+aux.getAbsolutePath());
639 }
640 } else {
641     System.out.println("Acesso aos arquivos cancelado pelo usuário.");
642 }
643
644
645 }
646
647 private void jButton2ActionPerformed(java.awt.event.ActionEvent evt) {
648 // Botão OK-Frame1- Carrega arquivos para reconstrução 3D
649
650 // Variáveis
651 int fatiaInicial = Integer.parseInt(jTextField2.getText()); //Converte string para int (fatia inicial)
652 int fatiaFinal = Integer.parseInt(jTextField3.getText()); //Converte string para int (fatia final)
653 double dimx=Double.parseDouble(jTextField4.getText()); //dimensao pixel fatia em x
654 double dimy=Double.parseDouble(jTextField5.getText()); //dimensao pixel fatia em y
655 double dimz=Double.parseDouble(jTextField6.getText()); //dimensao pixel fatia em z
656 //Carrega as fatias BMP com o VTK
657 vtk.vtkBMPReader bmpreader_ = new vtk.vtkBMPReader();
658 bmpreader_.SetFilePrefix(textField1.getText());
659 bmpreader_.SetFilePattern("%s%04d.bmp");
660 bmpreader_.SetDataExtent(0, largImage-1, 0, altImage-1, fatiaInicial, fatiaFinal);
661 bmpreader_.SetDataScalarTypeToUnsignedChar();
662 bmpreader_.SetDataByteOrderToLittleEndian();
663 bmpreader_.SetDataSpacing(dimx, dimy, dimz);
664 bmpreader_.SetDataOrigin(0, 0, 0);
665 bmpreader_.UpdateWholeExtent();
666 bmpreader_.Update();
667 //Ativa botões Reconstruir das ABAS
668 jButton3.setEnabled(true);
669 jButton4.setEnabled(true);
670 jButton5.setEnabled(true);
671 jButton6.setEnabled(true);
672 //Ativa itens do Menu
673 VerMenuItem1.setEnabled(true);
674 bmpreader= bmpreader_;
675
676
677 }
678 }

```

No botão “Ok” da aba VOL da Figura B1, segue-se os seguinte código.

```

705 private void jButton4ActionPerformed(java.awt.event.ActionEvent evt) {
706 //----- Botão OK da aba VOLUME -----

```

```

707 //Remove o ator atual do vtkPanel
708 vtkPanel1.GetRenderer().RemoveActor(volumeatual);
709 vtkPanel1.GetRenderer().RemoveActor(atoratual);
710 vtkPanel1.GetRenderer().ResetCamera();
711 vtkPanel1.Render();
712 //
713 vtkImageExtractComponents iEC = new vtkImageExtractComponents();
714 iEC.SetInput(bmpreader.GetOutput());
715 iEC.SetComponents(1);
716 iEC.Update();
717 vtkImageData imData = iEC.GetOutput();
718 //vtkPointData pd = iEC.GetOutput().GetPointData();
719 /////////////// STATIC TRANSFER FUNCTION////////////////////
720 vtkColorTransferFunction colorTransferFunction = new vtkColorTransferFunction();
721 colorTransferFunction.RemoveAllPoints();
722 colorTransferFunction.AddRGBPoint(0, 0, 1, 0);
723 colorTransferFunction.AddRGBPoint(134, 0, 1, 0);
724 colorTransferFunction.AddRGBPoint(135, 1, 0, 0);
725 colorTransferFunction.AddRGBPoint(219, 1, 0, 0);
726 colorTransferFunction.AddRGBPoint(220, 0, 0, 1);
727 colorTransferFunction.AddRGBPoint(255, 0, 0, 1);
728
729 vtkPiecewiseFunction opacityTransferFunction = new vtkPiecewiseFunction();
730 opacityTransferFunction.RemoveAllPoints();
731 opacityTransferFunction.AddPoint(0.0, 0.01);
732 opacityTransferFunction.AddPoint(134, 0.01);
733 opacityTransferFunction.AddPoint(135, 0.03);
734 opacityTransferFunction.AddPoint(219, 0.03);
735 opacityTransferFunction.AddPoint(220, 1.0);
736 opacityTransferFunction.AddPoint(254, 1.0);
737 ///////////////
738
739 vtkVolumeProperty volumeProperty = new vtkVolumeProperty();
740 volumeProperty.SetColor(colorTransferFunction);
741 //volumeProperty.SetIndependentComponents(1);
742 volumeProperty.SetScalarOpacity(opacityTransferFunction);
743 //volumeProperty.ShadeOn();
744 volumeProperty.SetInterpolationTypeToLinear();
745 //volumeProperty.SetInterpolationTypeToNearest();
746 //volumeMapper.SetInput( (vtkImageData) spR.GetOutput());
747
748 vtkVolumeRayCastMapper volumeMapper = new vtkVolumeRayCastMapper();
749 volumeMapper.SetInput((vtkImageData) imData);
750 vtkVolumeRayCastCompositeFunction compositeFunction = new
751 vtkVolumeRayCastCompositeFunction();
752 volumeMapper.SetVolumeRayCastFunction(compositeFunction);
753
754 vtkVolume volume = new vtkVolume();
755 volume.SetMapper(volumeMapper);
756 volume.SetProperty(volumeProperty);
757 //An outline provides context around the data.
758 vtk.vtkOutlineFilter outlineData = new vtk.vtkOutlineFilter();
759 outlineData.SetInput(opacityTransferFunction);
760 vtk.vtkPolyDataMapper mapOutline = new vtk.vtkPolyDataMapper();
761 mapOutline.SetInput(outlineData.GetOutput());
762 vtk.vtkActor outline = new vtk.vtkActor();
763 outline.SetMapper(mapOutline);
764 outline.GetProperty();
765
766 //vtkRenderer ren1 = new vtkRenderer();

```

```

766     ren1.AddActor(outline);
767     ren1.AddVolume(volume);
768
769
770     vtkPanel1.GetRenderer().AddActor(volume);
771
772     vtkPanel1.GetRenderer().ResetCamera();
773     vtkPanel1.Render();
774     volumeatual=volume;
775
776 }

```

No botão “Ok” da aba SUP da Figura A1

```

778 private void jButton3ActionPerformed(java.awt.event.ActionEvent evt) {
779     //-----Botão OK da aba SUPERFÍCIE
780
781     // Variáveis
782     //Limiar Marching Cubes (Isovalor)
783
784     String limiarfinal = jTextField1.getText();//Limiar Final
785     int isovalor = Integer.parseInt(limiarfinal);//Converte string para int (limiar final)
786
787     //Remove o ator atual do vtkPanel
788
789     vtkPanel1.GetRenderer().RemoveActor(volumeatual);
790     vtkPanel1.GetRenderer().RemoveActor(atoratual);
791     vtkPanel1.GetRenderer().ResetCamera();
792     vtkPanel1.Render();
793     // vtkRenderWindow renWin = vtkPanel1.GetRenderWindow();
794
795     ren1 = new vtkRenderer();
796
797     //Sem filtro (via CheckBox)- Renderiza superfície sem filtro
798     if (jCheckBox1_semf.isSelected()){
799
800         vtkImageCast cast = new vtkImageCast();
801         cast.SetInput(bmpreader.GetOutput());
802         //Marching Cubes
803         vtkImageMarchingCubes marcher = new vtkImageMarchingCubes();
804         marcher.SetInput(cast.GetOutput());
805         marcher.SetValue(0,isovalor);
806         marcher.Update();
807         //
808         vtkPolyDataMapper skinMapper = new vtkPolyDataMapper();
809         skinMapper.SetInput(marcher.GetOutput());
810         skinMapper.ScalarVisibilityOff();
811         //
812         vtkActor skin = new vtkActor();
813         skin.SetMapper(skinMapper);
814         //
815         //vtkRenderer ren1 = new vtkRenderer();
816         ren1.AddVolume(skin);
817         //
818         vtkPanel1.GetRenderer().AddActor(skin);
819         vtkPanel1.GetRenderer().ResetCamera();
820         vtkPanel1.Render();
821         //
822         atoratual=skin;

```

```

823
824 }
825
826 //(via CheckBox)- Reconstrução da Superfície com Filtro Gaussiano
827 if (jCheckBox2_gauss.isSelected()){
828
829     vtkImageCast cast = new vtkImageCast();
830     cast.SetInput(bmpreader.GetOutput());
831     //
832     vtkImageGaussianSmooth filtrado = new vtkImageGaussianSmooth();
833     filtrado.SetInput(bmpreader.GetOutput());
834     filtrado.SetStandardDeviations(1.0, 1.0, 1.0);
835     filtrado.SetRadiusFactors(1.0, 1.0, 1.0);
836     filtrado.SetDimensionality(3);
837     filtrado.Update();
838     //Marching Cubes
839     vtkImageMarchingCubes marcher = new vtkImageMarchingCubes();
840     marcher.SetInput(filtrado.GetOutput());
841     marcher.SetValue(0,isovalor);
842     marcher.Update();
843     //
844     vtkPolyDataMapper skinMapper = new vtkPolyDataMapper();
845     skinMapper.SetInput(marcher.GetOutput());
846     skinMapper.ScalarVisibilityOff();
847     //
848     vtkActor skin = new vtkActor();
849     skin.SetMapper(skinMapper);
850     //
851     //vtkRenderer ren1 = new vtkRenderer();
852     ren1.AddVolume(skin);
853
854     vtkPanel1.GetRenderer().AddActor(skin);
855     vtkPanel1.GetRenderer().ResetCamera();
856     vtkPanel1.Render();
857     atoratual=skin;
858 }
859 //----(via CheckBox)-Reconstrução de Superfícies com Filtro da Mediana
860 if(jCheckBox3_median.isSelected()){
861
862     //
863     vtkImageMedian3D filtrado=new vtkImageMedian3D();
864     filtrado.SetInput(bmpreader.GetOutput());
865     //
866     filtrado.SetKernelSize(5, 5, 3);
867     filtrado.Update();
868
869     //Marching Cubes
870     vtkImageMarchingCubes marcher = new vtkImageMarchingCubes();
871     marcher.SetInput(filtrado.GetOutput());
872     marcher.SetValue(0,isovalor);
873     marcher.Update();
874     //
875     //
876     vtkPolyDataMapper skinMapper = new vtkPolyDataMapper();
877     skinMapper.SetInput(marcher.GetOutput());
878     //
879     skinMapper.ScalarVisibilityOff();
880     //
881     vtkActor skin = new vtkActor();
882     skin.SetMapper(skinMapper);

```

```

883
884     // vtkRenderer ren1 = new vtkRenderer();
885     ren1.AddVolume(skin);
886
887     //
888     vtkPanel1.GetRenderer().AddActor(skin);
889     vtkPanel1.GetRenderer().ResetCamera();
890     vtkPanel1.Render();
891     atoratual=skin;
892 }
893 //CAMERA
894 // It is convenient to create an initial view of the data. The FocalPoint
895 // and Position form a vector direction. Later on (ResetCamera() method)
896 // this vector is used to position the camera to look at the data in
897 // this direction.
898 vtk.vtkCamera aCamera = new vtk.vtkCamera();
899 aCamera.SetViewUp(0, 0, -1);
900 aCamera.SetPosition(1, 1, 1);
901 aCamera.SetFocalPoint(0, 0, 0);
902 aCamera.ComputeViewPlaneNormal();
903 aCamera.GetClippingRange();
904 aCamera.GetParallelScale();
905 aCamera.GetOrientation();
906 }

```

No botão “Ok” da aba MED da Figura B1 tem-se

```

912 private void jButton6ActionPerformed(java.awt.event.ActionEvent evt) {
913     //----- Botão Calcular aba Medidas:
914 //----- Botão Calcular aba Medidas:
915
916 //Remove o ator atual do vtkPanel
917 vtkPanel1.GetRenderer().RemoveActor(volumeatual);
918 vtkPanel1.GetRenderer().RemoveActor(atoratual);
919 vtkPanel1.GetRenderer().RemoveActor(textoatual);
920 vtkPanel1.GetRenderer().ResetCamera();
921 vtkPanel1.Render();
922 //Limiar Marching Cubes (Isovalor)
923
924 String limiarfinal = jTextField7.getText();//Limiar Final
925 int isovalor = Integer.parseInt(limiarfinal);//Converte string para int (limiar final)
926
927 vtkImageCast cast = new vtkImageCast();
928 cast.SetInput(bmpreader.GetOutput());
929 //Marching Cubes
930 vtkImageMarchingCubes marcher = new vtkImageMarchingCubes();
931 marcher.SetInput(cast.GetOutput());
932 marcher.SetValue(0,isovalor);
933 marcher.Update();
934
935
936
937 // //Transformação da malha em triangulos
938 // vtkTriangleFilter triangles = new vtkTriangleFilter();
939 // triangles.SetInput(marcher.GetOutput());
940 // triangles.Update();
941
942 vtkPolyDataConnectivityFilter conn =new vtkPolyDataConnectivityFilter();
943 conn.SetInput(marcher.GetOutput());

```

```

944 conn.SetExtractionModeToSpecifiedRegions();
945 conn.InitializeSpecifiedRegionList();
946 conn.AddSpecifiedRegion(0);
947 conn.ColorRegionsOn();
948 conn.Update();
949
950 //Mapper
951     vtkPolyDataMapper isoMapper = new vtkPolyDataMapper();
952     isoMapper.SetInput(conn.GetOutput());
953     isoMapper.ScalarVisibilityOff();
954
955     vtkActor isoActor = new vtkActor();
956     isoActor.SetMapper(isoMapper);
957
958     //Ator texto
959     vtkTextProperty tprop = new vtkTextProperty();
960     tprop.BoldOn();
961     tprop.SetFontFamilyToCourier();
962     tprop.SetFontSize(12);
963
964     vtkTextMapper textoMapa = new vtkTextMapper();
965     textoMapa.SetTextProperty(tprop);
966
967     vtkTextActor textoAtor = new vtkTextActor();
968     textoAtor.GetTextProperty().SetFontSize(14);
969     textoAtor.GetTextProperty().BoldOn();
970     textoAtor.VisibilityOff();
971     textoAtor.SetTextScaleModeToProp();
972     textoAtor.SetMapper(textoMapa);
973 //VTK camera
974 vtkCamera aCamera = new vtkCamera();
975 aCamera.SetViewUp(0, 1, -1);
976 aCamera.SetPosition(0, 1, 0);
977 aCamera.SetFocalPoint(0, 0, 0);
978 //aCamera.ComputeViewPlaneNormal();
979 //Declarações
980 // vtkRenderer ren1 = new vtkRenderer();
981 vtkTriangleFilter tris = new vtkTriangleFilter();
982 vtkMassProperties Medidas = new vtkMassProperties();
992 try {
993     //Cria um diretório
994     File diretorio = new File("/home/walmor/medidas");
995     diretorio.mkdir();
996
997
998     //----- CRIA ARQUIVO PARA ARMAZENAR DADOS MEDIDOS-----
999     String nomeArquivo = null;
1000     nomeArquivo = "medidas.dat";//arquivo criado
1001     //Cria um arquivo
1002     File arquivo = new File(diretorio,nomeArquivo);
1003     prt = new PrintWriter(arquivo);
1004
1005     arq.append("No. Região, Forma Esfera, Area Superficial, Volume, VolumeX, VolumeY, VolumeZ, Kx,
Ky, Kz"+"n");
1006 } catch (IOException e) {
1007 }
1008
1009
1010
1011 int idx;//contador de superfícies encontradas

```

```

1012 //O loop abaixo varre todos as superfícies extraídas por conn
1013 for(idx=0; idx<conn.GetNumberOfExtractedRegions(); idx++){
1014 conn.DeleteSpecifiedRegion(idx-1);
1015 conn.AddSpecifiedRegion(idx);
1016 conn.Update();
1017
1018 ---Filtro para transformar malha em triângulos. Necessário para utilizar o vtkMassProperties
1019 tris.SetInput(conn.GetOutput());
1020 tris.Update();
1021
1022 //marcher.SetInput(conn.GetOutput());
1023 //marcher.GetComputeGradients();
1024 //-----
1025 ---Medidas
1026
1027 // gradientmagnitude.SetInput(conn.GetOutput());
1028 // double Gradiente=gradientmagnitude.GetOutput().GetScalarSize();
1029 // gradientmagnitude.Update();
1030 // double Gradiente = gradientmagnitude.GetOutput().GetScalarTypeMax();
1031
1032 //Medidas de Forma, Area Superficial e Volume
1033 Medidas.SetInput(tris.GetOutput());
1034 double FormaIndexD = Medidas.GetNormalizedShapeIndex();/*Compute and return
1035 the Normalized Shape Index (NSI). This characterizes the deviation of the shape
1036 of an object from a sphere. A sphere's NSI is one. This number is always >= 1.0.*/
1037 double AreaSupD = Medidas.GetSurfaceArea();//Medida da área superficial
1038 double VolumeD = Medidas.GetVolume();//Medida do volume
1039 double VolumeXD=Medidas.GetVolumeX();//Medida do volume em X
1040 double VolumeYD=Medidas.GetVolumeY();//Medida do volume em Y
1041 double VolumeZD= Medidas.GetVolumeZ();//Medida do volume em Z
1042 double KXD= Medidas.GetKx();//Medida do Maximum Unit Normal Component (MUNC)
1043 double KYD= Medidas.GetKy();//Medida do Maximum Unit Normal Component (MUNC)
1044 double KZD = Medidas.GetKz();//Medida do Maximum Unit Normal Component (MUNC)
1049 //Conversões double para string para plotar na tela
1050 // String Max=Double.toString(angul);//Do gradiente
1051 String FormaIndex =Double.toString(FormaIndexD);//Indice da forma de uma esfera NSI - converte
double para string
1052 String AreaSup = Double.toString(AreaSupD);//Area Superficial - converte double para string
1053 String Volume = Double.toString(VolumeD);//Volume - converte double para string
1054 String VolumeX=Double.toString(VolumeXD);//VolumeX - converte double para string
1055 String VolumeY=Double.toString(VolumeYD);//VolumeY - converte double para string
1056 String VolumeZ=Double.toString(VolumeZD);//VolumeZ - converte double para string
1057 String Kx=Double.toString(KXD);
1058 String Ky=Double.toString(KYD);
1059 String Kz=Double.toString(KZD);
1060 // String Cores=Integer.toString(color);
1061 //Imprime as medidas no console do Netbeans
1062 System.out.println(idx+" "+ FormaIndex +" "+ AreaSup + " "+ Volume + " "+ VolumeX + " "+
1063 VolumeY+" "+VolumeZ+" "+Kx+" "+Ky+" "+Kz);
1064 //Buffer para as mediads
1065 arq.append(idx+" "+ FormaIndex+" "+ AreaSup + " "+ Volume+" "+VolumeX+" "+
VolumeY+" "+VolumeZ+" "+Kx+" "+Ky+" "+Kz+"\n");//
1066
1067 // ESCRIBE MEDIDAS NA TELA
1068 textoAto.VisibilityOn();
1069 textoAto.SetInput("No. Regiao: "+idx+"\n" + "Indice Forma: " + FormaIndex+"\n" + "Area: " + AreaSup
+ "\n" + "Volume: " +
1070 Volume+" "\n" + "VolumeX: " +VolumeX+" "\n" + "VolumeY: " +VolumeY+" "\n" + "VolumeZ:
"+VolumeZ+" "\n" + "Kx: " +Kx+" "\n" + "Ky: " +
1071 Ky+" "\n" + "Kz: " +Kz);

```



```

1072
1073
1074
1075         ren1.AddActor(isoActor);
1076         ren1.AddActor(textoAtor);
1077         vtkPanel1.GetRenderer().AddActor(isoActor);
1078         vtkPanel1.GetRenderer().AddActor(textoAtor);
1079         vtkPanel1.GetRenderer().ResetCamera();
1080         vtkPanel1.Render();
1081
1082     }
1083     prt.println(arq.toString()); //Imprime no arquivo medidas.dat
1084     prt.close(); //Fecha o arquivo medidas.dat
1085     atoratual=isoActor;
1086     textoatual=textoAtor;
1093 }

```

Variáveis globais e declarações utilizadas no arquivo *LACVISView.java*.

```

1191 // Variables declaration - do not modify
1192 private javax.swing.JMenuItem ExportarMenu;
1193 private javax.swing.JMenuItem VerMenuItem1;
1194 private javax.swing.JButton jButton1;
1195 private javax.swing.JButton jButton2;
1196 private javax.swing.JButton jButton3;
1197 private javax.swing.JButton jButton4;
1198 private javax.swing.JButton jButton5;
1199 private javax.swing.JButton jButton6;
1200 private javax.swing.JCheckBox jCheckBox1_semf;
1201 private javax.swing.JCheckBox jCheckBox2_gauss;
1202 private javax.swing.JCheckBox jCheckBox3_median;
1203 private javax.swing.JFrame jFrame1;
1204 private javax.swing.JLabel jLabel1;
1205 private javax.swing.JLabel jLabel10;
1206 private javax.swing.JLabel jLabel11;
1207 private javax.swing.JLabel jLabel12;
1208 private javax.swing.JLabel jLabel13;
1209 private javax.swing.JLabel jLabel2;
1210 private javax.swing.JLabel jLabel3;
1211 private javax.swing.JLabel jLabel4;
1212 private javax.swing.JLabel jLabel5;
1213 private javax.swing.JLabel jLabel6;
1214 private javax.swing.JLabel jLabel7;
1215 private javax.swing.JLabel jLabel8;
1216 private javax.swing.JLabel jLabel9;
1217 private javax.swing.JMenuItem jMenuItem1;
1218 private javax.swing.JPanel jPanel2;
1219 private javax.swing.JPanel jPanel3;
1220 private javax.swing.JPanel jPanel7;
1221 private javax.swing.JPanel jPanel8;
1222 private javax.swing.JTabbedPane jTabbedPane1;
1223 private javax.swing.JTextField jTextField1;
1224 private javax.swing.JTextField jTextField2;
1225 private javax.swing.JTextField jTextField3;
1226 private javax.swing.JTextField jTextField4;
1227 private javax.swing.JTextField jTextField5;
1228 private javax.swing.JTextField jTextField6;
1229 private javax.swing.JTextField jTextField7;
1230 private javax.swing.JPanel mainPanel;

```



```

1231 private javax.swing.JMenuBar menuBar;
1232 private javax.swing.JProgressBar progressBar;
1233 private javax.swing.JLabel statusAnimationLabel;
1234 private javax.swing.JLabel statusMessageLabel;
1235 private javax.swing.JPanel statusPanel;
1236 private java.awt.TextField textField1;
1237 private javax.swing.JMenu verMenu;
1238 // End of variables declaration
1239 //
1240 private final Timer messageTimer;
1241 private final Timer busyIconTimer;
1242 private final Icon idleIcon;
1243 private final Icon[] busyIcons = new Icon[15];
1244 private int busyIconIndex = 0;
1245 //
1246 private JDialog aboutBox;
1247 //
1248 private int largImage, altImage; //largura e altura fatias utilizadas na reconstrução 3D
1249 private vtk.vtkVolume volumeatual; //necessario para remover o ator (volume) do vtkpanel
1250 private vtk.vtkActor atoratual; //necessario para remover o ator (superfície) do vtkpanel
1251 private vtk.vtkTextActor textoatual; //remove ator texto
1252 private vtk.vtkBMPReader bmpreader; //BMP Reader
1253 private vtk.vtkJPEGReader jpgreader; // JPEG
1254 //StringBuffer arq = new StringBuffer();//Buffer para arquivo
1255 //PrintWriter prt; //Imprime no arquivo
1256 // private vtk.vtkImageData my_ImageData;
1257 // private vtk.vtkImagePlaneWidget planeWidgetX;
1258 private vtkRenderer ren1;
1259 StringBuffer arq = new StringBuffer();//Buffer para arquivo
1260 PrintWriter prt; //Imprime no arquivo
1261 }

```


APÊNDICE B – DADOS UTILIZADOS

A Tabela B1 apresenta os dados obtidos das características calculadas para 50 objetos em tomografia 3D de isoladores poliméricos.

TABELA B1 - LEVANTAMENTO DE CARACTERÍSTICAS 3D OBTIDAS. FONTE: O AUTOR.

Id	Forma Esfera	Área Superficial	Volume	VolumeX	VolumeY	VolumeZ	Kx	Ky	Kz
-1	3,55388 89716	1007903,73862 80800	2119780,195265 7000	43844608,51313 25000	40683401,03558 32000	- 33909849,802903 8000	0,2121493 766	0,2050387 881	0,5828118 354
-1	0,76856 57080	13504,3992451 469	325045,1627987 510	- 1768251,249122 5900	232837,1490867 550	232837,14908675 40	0,2787894 390	0,2638719 526	0,4573386 084
-1	0,52168 12773	11223,4229424 473	787491,8275188 730	- 1662960,509555 9700	- 1400211,153484 8900	186901,05058535 70	0,3382725 307	0,2196665 906	0,4420608 787
-1	1,14530 34417	163814,888665 5020	4149943,388827 2200	- 4213562,492444 8900	- 4213562,492444 7900	- 3705899,9924448 900	0,4361270 947	0,4385551 920	0,1253177 133
1	1,01028 53869	359,266261015 7	620,9637538197	-620,9637538197	-620,9637538197	-620,9637538197	0,3076463 560	0,3157108 722	0,3766427 718
1	1,00749 44996	312,308521802 9	507,4830180544	-507,4830180544	-507,4830180544	-507,4830180544	0,3208161 866	0,3928326 475	0,2863511 660
1	1,00651 82214	615,217296241 8	1407,186609807 4	- 1407,186609807 4	- 1407,186609807 4	- 1407,1866098074	0,3691630 747	0,3306393 678	0,3001975 575
1	1,02126 03137	1398,66449873 32	4617,796329593 8	- 4617,796329593 9	- 4617,796329593 9	- 4617,7963295938	0,5052986 513	0,2744460 501	0,2202552 987
1	1,11615 98656	1908,80164428 51	5639,437748739 9	- 5639,437748739 9	- 5639,437748739 9	- 5639,4377487400	0,4147058 824	0,3386678 201	0,2466262 976
1	1,01947 52193	336,240553198 4	547,1657811280	-547,1657811280	-547,1657811280	-547,1657811280	0,4241245 136	0,2174124 514	0,3584630 350
1	1,02191 34198	1486,77753185 70	5051,268922175 5	- 5051,268922175 5	- 5051,268922175 5	- 5051,2689221755	0,2653489 069	0,4910901 069	0,2435609 464
1	1,07851 30462	851,104036852 1	1861,108017987 5	- 1861,108017987 5	- 1861,108017987 5	- 1861,1080179875	0,4679197 995	0,3194235 589	0,2126566 416
1	1,01844 65997	804,951942646 9	2032,890352935 0	- 2032,890352935 0	- 2032,890352935 0	- 2032,8903529349	0,3595881 069	0,4344653 573	0,2059465 357
1	1,00549 37146	1423,98972340 61	4970,453504351 4	- 4970,453504351 4	- 4970,453504351 4	- 4970,4535043514	0,2912403 101	0,4305426 357	0,2782170 543
1	1,00598 11112	747,615965734 1	1888,087798017 2	- 1888,087798017 2	- 1888,087798017 2	- 1888,0877980173	0,4086707 746	0,2812500 000	0,3100792 254
1	1,00876 02895	850,892999810 2	2273,643169320 8	- 2273,643169320 8	- 2273,643169320 8	- 2273,6431693208	0,2814573 762	0,4056916 794	0,3128509 444
1	1,02142 73427	1227,51040280 47	3794,802230645 9	- 3794,802230645 9	- 3794,802230645 9	- 3794,8022306458	0,4562294 182	0,1916849 616	0,3520856 202
1	1,08264 77932	1226,84372444 43	3184,168904511 7	- 3184,168904511 7	- 3184,168904511 7	- 3184,1689045118	0,3394170 168	0,4912027 311	0,1693802 521
1	1,02041 18817	52,1653433804	33,3442073751	-33,3442073751	-33,3442073751	-33,3442073751	0,3315972 222	0,3654513 889	0,3029513 889
1	1,02477 81122	793,148022992 1	1951,711672963 3	- 1951,711672963 2	- 1951,711672963 2	- 1951,7116729633	0,4479336 596	0,2014002 175	0,3506661 229
1	1,00780 02827	1700,89940974 66	6444,189922178 7	- 6444,189922178 8	- 6444,189922178 7	- 6444,1899221786	0,4200819 672	0,3135245 902	0,2663934 426
1	1,07799 75015	1586,48363296 97	4743,227383062 5	- 4743,227383062 5	- 4743,227383062 5	- 4743,2273830625	0,4731034 969	0,3326635 646	0,1942329 385
1	1,00856 85192	1559,46650856 57	5644,450474369 2	- 5644,450474369 3	- 5644,450474369 3	- 5644,4504743691	0,2797518 331	0,3767272 984	0,3435208 686
-1	0,27954 46618	6194,12467999 61	2098408,890452 0100	- 311984,5053854 570	- 265281,0820656 770	- 2424944,9023742 900	0,0928338 380	0,0603713 354	0,8467948 267
-1	0,28693 33989	7627,05096142 58	2651340,323002 4500	- 305977,6073259 860	- 34638,65297434 55	- 3029941,8671145 200	0,0640922 113	0,0665724 558	0,8693353 329
-1	0,13111 17654	96,0408455955	39267,45738348 65	20,0005289714	20,0005289714	- 40354,999471028 6	0,0134680 135	0,0134680 135	0,9730639 731
-1	4,35543 85412	99007,3578371 562	35455,15186801 14	- 4470899,347678 5000	- 2033563,221829 3300	1336143,0662350 100	0,1406769 816	0,1435646 535	0,7157583 649
-1	1,41753 28988	772654,571290 7550	22420868,92944 08000	14972038,30337 40000	11038864,71264 50000	- 40601648,665339 2000	0,1726613 091	0,1662523 014	0,6610863 895

-1	1,12994 81271	67785,2287159 814	1150272,910378 7600	-	1150272,910378 7600	-	1150272,910378 500	0,3917692 829	0,3963682 764	0,2118624 407
-1	1,57274 15991	1436353,40351 12900	41609610,73007 64000	-	10747198,27959 43000	-	10464614,47058 09000	0,1802112 601	0,1863688 548	0,6334198 851
1	1,10612 92703	895,587560251 3	1862,165335634 1	-	1862,165335634 0	-	1862,165335634 0	0,2136123 680	0,1142533 937	0,6721342 383
1	1,08253 63402	365,109478815 0	517,1077211680	-	517,1077211680	-	517,1077211680	0,1736842 105	0,2421052 632	0,5842105 263
-1	1,11066 31172	93520,2360015 486	1962841,150117 7300	-	1962841,150117 7200	-	1962841,150117 7700	0,3946265 117	0,3941851 561	0,2111883 323
-1	1,51424 66900	763822,356789 0610	18078919,16801 19000	-	14830411,21832 24000	-	11879924,79890 36000	0,1488808 836	0,1800793 612	0,6710397 552
-1	1,20649 52790	39,2067065963	13,1443004215	-	638,2500038097	-	18,8333336463	0,0086580 087	0,0086580 087	0,9826839 827
-1	1,62732 33554	21,9897445794	2,2500000000	-	2,2500000000	-	2,2500000000	0,1666666 667	0,1666666 667	0,6666666 667
-1	1,51819 43362	89,0562137634	22,58333337704	-	22,58333337704	-	22,58333337704	0,1145038 168	0,1145038 168	0,7709923 664
-1	0,00000 00000	0,5000000000	0,0000000000	-	0,0000000000	-	0,0000000000	0,3055555 556	0,3055555 556	0,3888888 889
-1	1,46207 40814	80,6636849771	21,7962994308	-	21,7962994308	-	21,7962994308	0,0253623 188	0,0253623 188	0,9492753 623
-1	1,05210 86263	16,3407168985	5,3333333333	-	5,3333333333	-	5,3333333333	0,3912037 037	0,3287037 037	0,2800925 926
-1	0,99274 60823	0,5728219619	0,0416666667	-	103,7083333333	-	0,0416666667	0,0000000 000	0,0000000 000	1,0000000 000
-1	0,56708 56998	80,0380314943	369,2090382701	-	72,1145847564	-	8450,947884942 1	0,0517799 353	0,0517799 353	0,8964401 294
-1	0,42882 58738	85,8497935157	948,5052785618	-	3400,993038699 0	-	12109,07640336 45	0,0648567 119	0,0648567 119	0,8702865 762
-1	1,08561 85342	21,5132607100	7,3333333333	-	7,3333333333	-	7,3333333333	0,2083333 333	0,4583333 333	0,3333333 333
1	1,05447 85090	7337,38947713 00	50404,92503786 58	-	50404,92503786 54	-	50404,92503786 56	0,2318238 571	0,2033230 887	0,5648530 542
-1	1,13635 39190	76533,4891203 270	1356782,522955 9300	-	1356782,522955 9400	-	1356782,522955 9300	0,3760866 788	0,3778232 889	0,2460900 323
1	1,26056 06398	2685,83565205 33	6534,340140019 1	-	6534,340140019 0	-	6534,340140019 0	0,1235021 097	0,5077426 160	0,3687552 743
-1	1,15835 61860	1046,44050348 22	2047,949569702 1	-	41623,29368082 68	-	1519,431538899 7	0,0826878 944	0,0753729 203	0,8419391 853
-1	0,86049 49022	1129,91636417 53	5605,293471945 0	-	78221,60909525 55	-	1541,433965047 2	0,0895994 832	0,0762273 902	0,8341731 266
-1	0,93828 28597	2776,94260995 86	16657,99860637 06	-	57252,81059265 13	-	217989,2584991 440	0,0617032 393	0,0864681 296	0,8518286 311